



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

DETEKCE AUTOMOBILŮ V OBRAZE

DETECTION OF VEHICLES IN IMAGE

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

JAKUB ŠPAŇHEL

VEDOUcí PRÁCE

SUPERVISOR

doc. Ing. ADAM HEROUT, Ph.D.

BRNO 2013

Abstrakt

Tato práce si klade za cíl implementovat metodu detekce a sledování automobilu založenou na modelu pohybu, vhodnou pro zpracování v reálném čase. Je zde uveden rozbor běžně užívaných metod detekce a představen princip této metody, který se skládá z detekce nízkoúrovňových klíčových bodů, časoprostorového profilování snímků i klíčových bodů a klasifikací získaných stop pomocí HMM. Následně byly s metodou prováděny experimenty sloužící k nalezení oblastí potenciálního zlepšení metody.

Abstract

This thesis aims to implement the vehicle detection and tracking method based on the motion model suitable for real-time processing. The first part includes analysis of the commonly used methods. The second part introduces principles of implemented method. This method consists of low-level features extraction, the spatiotemporal profiling of extracted features and image intensities, and classification of obtained traces based on HMM. Subsequently experiments using this trustworthy method are conducted to locate areas of potential method improvements.

Klíčová slova

Detekce vozidel, sledování vozidel, detekce klíčových bodů, dynamická identifikace cíle, video záběry z vozidla, skrytý Markovovský model (HMM), pravděpodobnosti, sledování, pohyb vozidla, 1-D profilování, zpracování v reálném čase OpenCV

Keywords

Vehicle detection, vehicle tracking, feature detection, dynamic target identification, in-car video, hidden Markov model (HMM), probability, tracking, vehicle motion, 1-D profiling, real-time processing, OpenCV

Citace

Jakub Špaňhel: Detekce automobilů v obraze, bakalářská práce, Brno, FIT VUT v Brně, 2013

Detekce automobilů v obraze

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana doc. Ing. Adama Herouta, Ph.D. Další informace mi poskytl pan doc. Dr. Ing. Jan Černocký. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Jakub Špaňhel
15.5.2013

Poděkování

Chtěl bych poděkovat panu doc. Ing. Adamu Heroutovi, Ph.D. za vedení této práce, jeho cenné rady, konstruktivní nápady a připomínky. Dále pak doc. Dr. Ing. Janu Černockému za jeho ochotu, pomoc a poskytnutí informací o Hidden Markov Model.

© Jakub Špaňhel, 2013.

Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.

Obsah

1	Úvod	2
2	Běžně užívané metody detekce automobilů	3
2.1	Metody založené na tvaru	4
2.2	Metody založené na výskytu a vzhledu vozidla	6
2.3	Metody využívající statickou kameru	6
3	Detekce automobilů v moderním pojetí	8
3.1	Myšlenka práce	9
3.2	Dynamické prostředí videa z automobilu	10
3.3	Extrakce klíčových bodů v reálném čase	12
3.4	Vertikální profilování snímků a klíčových bodů	15
3.5	Sledování klíčových bodů	17
3.6	Modelování pohybu scény pomocí HMM	18
3.7	Identifikace vozidla na základě pohybu	27
4	Implementace a vyhodnocení	31
4.1	Implementace	31
4.2	Testování a experimenty	36
4.3	Vyhodnocení	38
5	Závěr	42
A	Obsah DVD	46

Kapitola 1

Úvod

Kontrola dopravní situace a vozidel před námi je pro zvýšení bezpečnosti nás i ostatních velmi důležitá. Stejně důležité je i předcházet dopravním nehodám a zajistit bezpečí lidí na palubě, což si kladou za vizi své budoucí praxe i významné automobilky, jakou je například i Škoda auto a.s. [2]. Směrem do budoucna se navíc můžeme zabývat otázkou automatického řízení a jeho realizace, kde bude rovněž nutno zajistit bezpečí posádky automobilu i okolí.

Tato práce se zabývá implementací systému detekování a sledování vozidel založeném na modelu pohybu, představené kolektivem autorů kolem pana Amirali Jazayeri ve článku Vehicle Detection and Tracking in Car Video Based on Motion Model [14]. Tento článek byl vybrán na základě dohody s vedoucím práce. Mým úkolem bylo důkladně nastudovat, implementovat, otestovat a experimentovat s touto metodou a hledat tak situace, kdy je metoda použitelná či nikoliv, dále pak navrhnout případné změny původního návrhu. Cílem této práce je detekovat vozidla jedoucí před námi, nebo i ty které jsou již sledovány, a průběžně je ve videu sledovat. Systém je tedy navržen tak, aby byl schopný identifikovat vozidla jedoucí před námi ve stejném směru jako naše vozidlo. Toho je dosaženo díky jejich neustálého sledování pomocí vestavěné videokamery ve vozidle. Hlavním problémem je způsob identifikace vozidla v měnícím se prostředí a osvětlení [14]. Pro účely této práce byla použita přenosná kamera značky Omega, tzv. černá skříňka.

Na následujících stránkách se můžete seznámit s doposud používanými technikami na detekci automobilu v kapitole 2. Kapitola 3 popisuje mé pochopení studovaného článku a návrh metody detekce. Implementaci, testování, experimentování a vyhodnocení je věnována kapitola 4.

Kapitola 2

Běžně užívané metody detekce automobilů

Ačkoli máme k dispozici množství publikací zabývajících se rozpoznáváním nebo sledováním objektů a kombinaci obou přístupů. Téměř žádná z těchto technik nemůže být úspěšně použita v reálném čase pro video z vestavěné kamery (černé skřínky), které musí zpracovat tzv. „za letu“, tj. během pohybu vozidla. Systém představený ve článku [14] představuje usilí navrhnout a implementovat takové algoritmy a systémy zaměřené na zpracování v reálném čase, které jsou vysoce přizpůsobivé silničním a dopravním scénám a jsou založené na doméně specifických znalostí o silnici, vozidle a jeho kontrole[14].

Video z vestavěné kamery (černé skřínky) jsou záběry z kamery směřující dopředu ve směru jízdy, jak je vidět na obrázku 2.1.

Pro jednu pohyblivou kameru není snadné získat informace z dynamické scény dostatečně rychle bez použití stereo nebo jiných pomocných senzorů, jak uvádí článek [24]. Hlavními problémy jsou

1. Enormní množství vzorků vozidel a rozmanitost jejich tvarů, barev a typů je obtížná na učení a modelování, jak lze vyčíst ze článku [21].
2. Detekce vozidla musí být udělána automaticky spolu se sledováním. Běžně užívané algoritmy předpokládají lehce detekovatelné cíle nebo určení výchozí pozice vozidla, jak je uvedeno ve článku [19].
3. Video z automobilu může čelit drastickým změnám prostředí a osvětlení, podle článku [3]. Přechody mezi světly a stíny, ztráta barvy za zatažených dnů, odlesky na vozidlech, překrytí jinými vozidly aj., dělají extrakci klíčových bodů, rozpoznávání a sledování nestabilní [14].

Následující sekce reflektují jednotlivé kategorie běžně užívaných metod detekce automobilů a jednotlivé metody doplňují o krátký popis jejich specifik.



Obrázek 2.1: Typický snímek videopohledu z automobilu - rozlišení 640x480. Tento pohled je velice důležitý pro analýzu problému detekce a sledování vozidel. Horní polovina snímku je zabrána oblohou, kterou lze při detekci klíčových bodů ignorovat. Dále můžeme na snímku vidět cestu zužující se k horizontu. Tato část snímku je pro nás velice důležitá, jelikož se v této části snímků vyskytují vozidla. Proto jí budeme klást větší význam dále při zpracování snímků. Podél cesty se pak vyskytuje statické pozadí. Dolní část snímku je tvořena statickou částí pozorovatelského automobilu, která je všudypřítomná na všech záběrech.

2.1 Metody založené na tvaru

Metody detekce automobilů, založené na tvaru automobilu, obvykle trpí svoji křehkostí v závislosti na rozmanitosti tvaru vozidel a pozadí. Jako zástupce této kategorie lze například uvést metody ze článků [1] a [15].

Například metoda uvedená ve článku [1], zabývající se detekcí vozidel v reálném čase, je založena na hypotéze přítomnosti vozidel v obdélníkových podoblastech na základě výskytu robustní klasifikace vektorů klíčových bodů. Jeden vektor je vyextrahován z každé oblasti, která by mohla obsahovat vozidla. Je připravena vzorová množina vektorů tříd vozidel a objektů vozidlům neodpovídajícím. Hypotéza je následně ověřena výpočtem Mahalanobisových vzdáleností mezi vektory.

2.1.1 Symetrické vlastnosti

Metoda představená ve článku [15] identifikuje oblasti zájmu na základě oblastí věrohodnosti výskytu cílového vozidla, které je potvrzeno pomocí symetrického charakteru obrysu vozidla, a pomocí osy symetrie je zjištěna pozice vozidla. Vozidlo je dále sledováno pomocí principu Kalmanovy předpovědi v sérii snímků. Metoda poskytuje solidní výsledky jen za

určitých podmínek.

Článek [20] se zabývá interpretací dopravních scén. Detekce automobilů je založena hlavně na homogenitě předběžně segmentované matice obsahující horizontální úsečky řádně umístěné na zadní části vozidla a velikosti státní poznávací značky i zadního okna automobilu. I zde se tedy využívá symetrických vlastností.

Metodu detekování a sledování vozidel pomocí vyhledávání různorodých charakteristických klíčových bodů ze snímků z monochromatické kamery představuje článek [12]. Proces detekce využívá stínu a symetrie klíčových bodů pro vytvoření hypotéz o přítomnosti vozidla. Klíčové body jsou spojovány a sledovány pomocí metody Interacting Multiple Model. Detekce je úspěšná pro přírodní scenérie.

Další zajímavou alternativu nabízí metoda představená ve článku [8], která používá zastoupení červené barvy k nalezení oblastí koncových světel vozidel a využívá funkci měření symetrie pro analýzu symetrie rozložení barev a zjištění přesné pozice osy symetrie. Poté dochází k rekonstrukci hran vozidla a vytvoření ohraničení, které bude pasovat na detekovanou oblast vozidla. Metoda může být přesná i pro různé druhy počasí a světelné podmínky.

2.1.2 Modely deformovatelných rámců

Metoda představená ve článku [16], který se zabývá vytvořením segmentačního algoritmu za použití modelů deformovatelných šablon pro segmentaci vozidla od pozadí a jiných jedoucích vozidel, definuje polygonální šablony pro charakterizování základního modelu vozidla a odvozuje apriorní funkci hustoty pravděpodobnosti pro omezení deformovatelnosti šablony na množinu povolených tvarů. Věrohodnostní funkce hustoty pravděpodobnosti, kombinující pohybové informace a zaměření hrany, potom zajišťuje zahrnutí deformovatelné šablony v rámci pohyblivých oblastí.

Algoritmy pro efektivní lokalizaci a rozpoznávání vozidel v dopravních scenériích, které eliminují potřebu explicitní extrakce klíčových bodů a porovnávání, byly představeny ve článku [25]. Pozice a třída objektu je určena formou hlasování a jednorozměrných (1D) korelací založených přímo na gradientu obrazu, který může být počítán tzv. „za letu“.

Metoda lokalizace vozidel z více kamer je představena ve článku [10]. Metoda je schopná detekovat vozidla z různých úhlů pohledu a tím tedy různých vzhledů automobilu. Problém porovnávání vozidel pozorovaných pod různými úhly je eliminován na porovnávání vnořených vlastností objektu místo porovnávání obrazu jako celku. Metoda poskytuje vcelku povzbudivé výsledky pro rozměrnou množinu dat.

Vytvářením 3D modelu vozidla z barevného videa jedné nekalibrované dopravní kamery se zabývá článek [9]. Metoda používá trigonometrické vztahy 2D klíčových bodů a geometrické vztahy jednoho 3D generického modelu vozidla pro mapování 2D klíčových bodů do přímé 3D projekce s deformačním efektem. Výkonnost navrhované metody pro několik typů vozidel, ze dvou značně rozdílných pozorovacích míst, je velmi nadějná pro její použitelnost v 3D rekonstrukci jiných pevných objektů ve videu.

2.2 Metody založené na výskytu a vzhledu vozidla

Metody uvedeny v této sekci zmiňují pravděpodobnosti při jejich vytváření, ale tyto pravděpodobnosti se týkají zejména výskytu a vzhledu vozidel, případně rozložení jejich intenzit [14].

Například metoda představena ve článku [21], je schopná detekovat lidské obličeje a osobní automobily. Tato metoda detekce 3D objektů používá histogramy vzhledu objektů, které chce detekovat a jejich protikladů. Každý histogram reprezentuje průměrnou statistiku podmnožiny vlnových koeficientů a její pozice na objektu. Metoda je založena na použití velkého množství histogramů reprezentujících široké spektrum vizuálních atributů a je schopná detekovat osobní automobily z různých úhlů pohledu.

Další statistický přístup pro automatickou detekci vozidel, tentokrát založený na lokálních klíčových bodech, které jsou lokalizovány ve třech hlavních podoblastech, je představen ve článku [26]. Během procesu detekce dochází k projekci každé podoblasti do jejího přidruženého i nezávislého bazového prostoru pro získání váhového vektoru, pomocí analýzy hlavních komponent, a získání vektoru koeficientů, pomocí analýzy nezávislých komponent. Proces vyhodnocení věrohodnosti se pak provádí na základě předpokládané průměrné pravděpodobnosti projekcí váhových vektorů a vektorů koeficientů jednotlivých podoblastí společně s informací o pozici.

Detekci vozidla založenou na principu *Boosted Gabor features* se zabývá článek [5]. Detekce vozidla v tomto článku se skládá ze dvou fází, ze kterých se následně sestavuje struktura multirezoluční validační hypotézy. Ve fázi generování hypotézy přítomnosti vozidla se generují seznamy hypotéz tří hlavních oblastí zájmů s různými rezolucemi za použití horizontálních a vertikálních hran. Seznam hypotéz pro celý snímek je poté získán kombinací těchto tří seznamů. Pro potvrzení hypotézy dochází k validaci seznamu hypotéz pomocí algoritmu *Boosted Gabor feature*.

Soustavu aktivního učení pro rozpoznání a sledování vozidel využívá metoda představená ve článku [22]. Pasivně trénovaný rozpoznávací systém je založen na konvenčním učení s dohledem. Pomocí dotazů a archivace rozhraní pro aktivní učení je pasivně natrénovaný systém rozpoznávání vozidel vyhodnocen na nezávislé množině dat z reálného světa, informační vzorky jsou poté dotazovány a archivovány pro provedení selektivního výběru. Další kolo učení je provedeno pro vytvoření rozpoznávače vozidel založeného na metodě aktivního učení. Tato metoda dává poměrně kvalitní výsledky pro rozpoznávání a sledování vozidel z paluby automobilu.

Statistický přístup také používá metoda ze článku [8], která již byla zmíněna dříve.

2.3 Metody využívající statickou kameru

Další skupina metod detekce automobilu potom využívá pohled ze statické kamery. Například metoda představená ve článku [27] se zabývá přesnou segmentací jedoucích vozidel.

Segmentace je založena na Gaussovském modelu pohybu pro jedoucí vozidla v dynamických scénách. Zkoumáním rozdílu mezi vektory pohybu dynamického pozadí a vektory pohybu jedoucích vozidel lze zjistit, že pohybové vektory jedoucích vozidel se shlukují do menší oblasti, zatímco pohybové vektory dynamického pozadí se rozptylují.

Jinou alternativu k segmentaci jedoucích vozidel představuje článek [17]. Vzhledem k tomu, že stíny pohybujících se objektů často narušují sledování, tato metoda navrhuje segmentaci pomocí skrytého Markovova modelu (HMM¹), který v reálném čase klasifikuje každý pixel nebo region do tří kategorií: stíny, popředí a pozadí. Model provádí odhad stavu v reálném čase, čehož se využívá při segmentaci. Tato metoda byla testována na dopravních kamerách sledujících provoz, tudíž z pevného bodu.

Další možností rychlé detekce automobilu se věnuje článek [29]. Tato technika, která je tentokrát založena na přítomnosti více náznaků, využívá nehybného obrazu. Detekce se skládá ze dvou úrovní, kdy první je založená na získání náznaků hran a dalších bodů zájmu, a druhá se zabývá modelováním a trénováním Gaborových momentů.

¹Hidden Markov Model

Kapitola 3

Detekce automobilů v moderním pojetí

Tato kapitola zevrubně popisuje mé pochopení, vylepšení a úpravy studované metody detekce a sledování automobilů představené ve článku [14]. Většina rovnic v této kapitole je převzata z tohoto článku, společně s některými úseky textu a obrázky, které jsou důležité pro pochopení souvislostí a dané problematiky.

Proces identifikace vozidla se skládá z několika souvisejících částí, které musí pracovat společně, jinak by nebylo možné korektně rozhodnout, zda-li je objekt vyskytující se v obraze vozidlem či nikoliv.

Tato metoda nejprve vybírá a detekuje nízkourovňové klíčové body vozidel, které jsou odolné vůči změnám osvětlení, tvaru nebo překrytí. Tím se snaží zabránit složitému vytváření modelů vozidla i scény a jejich učení na vyšší úrovni, které nemusí být stabilní.

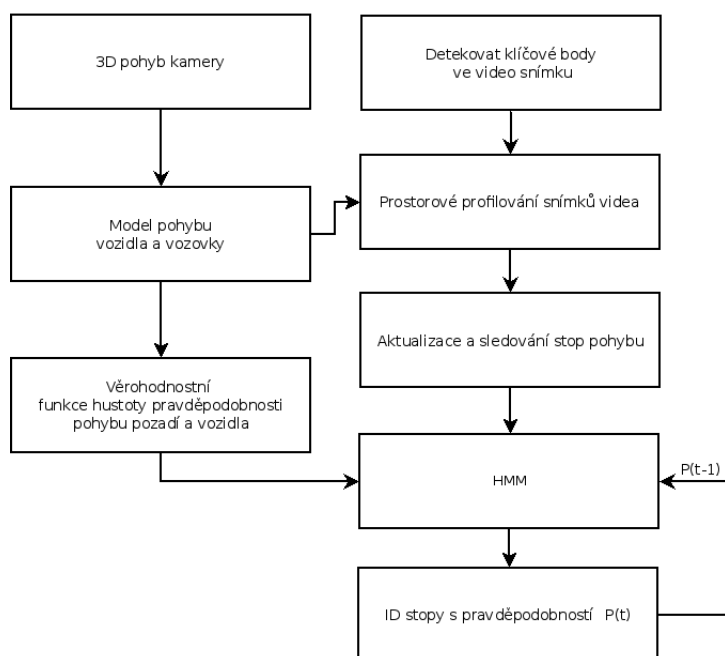
Následně se zaměřuje na horizontální pohyb scény pro rychlé zpracování snímků. Ze snímků videa jsou shromažďovány jednorozměrné (1D) profily, které zachycují horizontálního pohyb scény přímo ve stopách. Na těchto časových profilech poté dochází ke sledování trajektorií klíčových bodů tak, aby bylo možné provést, díky snížené prostorové dimenzi, klasifikaci vozidla a pozadí v reálném čase.

Dále je kladen větší důraz na pochopení chování pohybu vozidel než na analýze tvaru objektu při identifikaci cíle. Je zde použit skrytý Markovův model (HMM¹), který se používá při popisování sekvenčních dat, jak můžeme vyčíst ze článků [7] a [13], pro modelování souvislého pohybu klíčových bodů, takže výsledky nebudou tak moc ovlivněny prahováním během nízkourovňového zpracování. Identifikace cílových vozidel pak probíhá na základě pravděpodobností.

¹Hidden Markov Model

3.1 Myšlenka práce

Autoři článku [14] přišli se zjištěním, že lidé jsou schopni rozeznat vozidlo od pozadí, když jim je ukázán záznam souvislého pohybu extrahovaných bodů z videozáznamu i bez předchozích informací o tvaru a barvě, za předpokladu, že vědí, kde je zdroj. Během pohybu pozorovatelského vozidla po silnici je stanoven relativní pohyb pozadí vůči kameře. Předpokládá se, že pohyb promítnutý do snímku kamery je dále určen vzdáleností objektů. Tento pohyb má jedinečné vlastnosti společné s vlastním pohybem vozidla. Na druhou stranu, cílová vozidla pohybující se stejným směrem jako kamera, mají rozdílný pohyb oproti pozadí, a tedy zobrazují jiný optický tok než pozadí ve videu. Po prozkoumání charakteristik pohybu sledovaných objektů je možné tyto objekty rozdělit na statické pozadí a pohybující se automobily, jak je zobrazeno v procesu na obrázku 3.1.



Obrázek 3.1: Schéma detekce a sledování automobilů. Část vlevo znázorňuje teoretické základy, modely pohybu vozidla i vozovky a odpovídající funkce hustoty pravděpodobnosti, které jsou spočítány offline a jsou neměnné. Část vpravo potom zobrazuje dynamickou část procesu, složenou z hlavních komponent detekce a sledování automobilu, kdy každá část je neméně důležitá a nelze ji vynechat. Hlavní roli zde hraje prostorové profilování snímků videa, které se děje na základě klíčových bodů i snímků samotných. Z těchto profilů dochází k získávání hlavních stop, které jsou dále ponechány pro klasifikaci pomocí HMM. Schéma převzato ze článku [14].

Na rozdíl od jiných prací, které kladou větší úsilí na analýzu tvaru vozidla v jednotlivých snímcích videa, se tato metoda zaměřuje extrakci nízkoúrovňových klíčových bodů, jako jsou rohy, lokální extrémy intenzit a horizontální úsečky, což je dále popsáno v sekci 3.3. Pro zajištění ucelenosti dat a odolnosti jejich zpracování vůči záchvěvům, šumu, či nepodstatným klíčovým bodům dochází k profilování těchto klíčových bodů do časových

úseků. Pohyb scény se v časových profilech zobrazuje ve formě stop. Horizontální rychlost klíčových bodů v obraze je získávána během sledování těchto stop.

Pro identifikování sledovaných stop jako automobilu nebo pozadí, je potřeba vytvořit model pohybových vlastností scény ve videu, kterým se zabývá sekce 3.6. Vzhledem k tomu, že tok pozadí je orientovaný na pohyb kamery a závisí na pozici v obraze, dochází ke zkoumání toku obrazu s ohledem na pozici během pohybu kamery, což lze popsat pomocí jejich průměrných pravděpodobností. Následně dochází k určení rozdělení věrohodnosti pravděpodobností pro automobil a pro pozadí, respektive jsou stanoveny funkce hustoty pravděpodobností scény, pohybu kamery a hledaných vozidel. Na základě těchto funkcí je umožněna lepší reakce na očekávané pohybové události.

V sekci 3.7 dochází k odvození výpočtu posteriorních ohodnocení cílových vozidel a pozadí, na základě pozorování pohybových stop, tj. na detekované pozici stopy a rychlosti bodu v obraze pro každý okamžik. Pro dosažení stabilní klasifikace vozidel dochází k procesu vyhodnocení jejich pohybu pomocí HMM², kdy jsou stopy souvisle sledovány. Předem vypočtené věrohodnostní funkce hustoty pravděpodobnosti a věrohodnosti přechodu jsou použity v HMM pro odhad stavu stopy. Souvislý pohyb stopy v profilu poskytuje přesnější informace o vozidle, než tvary klíčových bodů, které mohou být ovlivněny osvětlením, pozadím, či dokonce překryty jinými klíčovými body.

3.2 Dynamické prostředí videa z automobilu

Požadované obecné předpoklady jsou následující:

1. Pozorovatelské vozidlo by nemělo úplně odbočit nebo být v příliš velké vzdálenosti od cílových vozidel na silnici.
2. Je vyžadován nepřetržitý pohyb pozorovatelského vozidla. Pro vozidla s vestavěnou kamerou čistě zatočení bez zřejmého pohybu vpřed, např. zatočení za roh ulice, neposkytuje dostatečné informace na oddělení pohybu cílů od pohybu pozadí, protože takové zatočení vytváří v podstatě stejný optický tok přes celý snímek.


Dalším zřejmým předpokladem je návaznost pohybu vozidla a kamery, který je zaručen hnacím mechanismem čtyřkolových vozidel.

Předpokládejme, že souřadný systém vycentrování kamery je $O-XYZ$ (nebo $O-xyz$), kdy osa X směřuje doprava, osa Y směřuje dolů a osa Z směřuje do směru pohybu vozidla. 3D pozice bodu scény je potom označena jako (X, Y, Z) v souřadném systému $O-XYZ$, a souřadnice jeho projekce v obraze jako (x, y) . Typický pohled ve videu z automobilu je znázorněn na obrázku 3.2, kde průsečík optických toků (FOE³) se nachází v prostřední části

²HMM - Hidden Markov Model

³FOE - Focus of expansion - Bod ve středu horizontu, ze kterého se zdá že vychází všechny pohyb. Průsečík optických toků.

obrazu $I(x, y)$. Na točité cestě dodává řízení pohybu kamery rotaci, jak je vidět na obrázku 3.2(b).



Obrázek 3.2: Typická scéna videopohledu z automobilu, kdy se automobil vyskytuje před námi a to jen v určité části snímku. Zbytek snímku poté zabírá obloha a statické pozadí. Červené šipky naznačují optický tok, nebo obrazovou rychlost. (a) Představuje přímou cestu, kdy se vozidlo vůči kameře pohybuje rovně, tedy optický tok není ovlivněn rotací. (b) Představuje mírně točitou cestu, kdy vozidlo mění svou pozici vůči kameře, a tedy optický tok je ovlivněn rotací. Převzato ze článku [14].

Cílové vozidlo pohybující se na silnici před námi může měnit svou horizontální pozici, a to změnou jízdního pruhu, a v případě změny rychlosti dokonce i svoji velikost. Přesto si však může udržet svoji pozici na cestě, i když se jeho okamžitá rychlost v obraze $u(x, y)$ výrazně změní. Nicméně pozadí má vlastní druh spojitého pohybu s optickým tokem pozvolně se rozšiřujícím z centra FOE ke stranám snímku obrazu. Rychlost v obraze roste společně s přibližujícím se scénou. Spojitost pohybu je třeba modelovat pro automatické rozlišení vozidla a pozadí. Vzhledem k perspektivní projekci kamery je poloha pohybujícího se bodu scény v obraze $P(X, Y, Z)$ odvozena jako

$$x(t) = \frac{fX(t)}{Z(t)} \quad y(t) = \frac{fY(t)}{Z(t)}, \quad (3.1)$$

kde f je ohnisková vzdálenost kamery. Označme relativní posunutí bodu scény $P(X, Y, Z)$ směrem ke kameře jako $(T_x(t), T_y(t), T_z(t))$, v souřadném systému $O-XYZ$. Rotace rychlostí pozorovatelského vozidla při stoupání, vybočení a natočení označíme jako $(R_x(t), R_y(t),$

$R_z(t)$) v radiánech za sekundu, kde stoupání a natočení pozorovatelského vozidla na přímé silnici bez výrazného převýšení má $R_x(t) \approx 0$ a $R_z(t) \approx 0$. Relativní rychlost bodu scény P ke kameře je tedy

$$(V_x(t), V_y(t), V_z(t)) = (T_x(t), T_y(t), T_z(t)) + (X, Y, Z) \times (R_x(t), R_y(t), R_z(t)), \quad (3.2)$$

podle článku [4]. Diferenciací rovnice (3.1) s ohledem na t a nahrazením souvisejících označení ve výsledku opětovným použitím rovnice (3.1), se horizontální složka rychlost bodu P v obraze stane

$$v(t) = \frac{\partial x(t)}{\partial t} = \frac{fV_x(t) - x(t)V_z(t)}{Z(t)}. \quad (3.3)$$

Nahrazením $V_x(t)$ a $V_z(t)$ rovnicí (3.2) a nastavením $R_x(t) = 0$ a $R_z(t) = 0$ dostaneme

$$v(t) = \frac{fT_x(t) - x(t)T_z(t)}{Z(t)} - \frac{x^2(t) + f^2}{f}R_y(t) = v^{(t)}(t) + v^{(r)}(t), \quad (3.4)$$

když označíme

$$v^{(t)}(t) = \frac{fT_x(t) - x(t)T_z(t)}{Z(t)} \quad v^{(r)}(t) = -\frac{x^2(t) + f^2}{f}R_y(t), \quad (3.5)$$

jako složky horizontální rychlosti bodu v obraze z pohybu a rotace navzájem. Pokud se pozorovatelské vozidlo pohybuje na přímé vozovce, tj. $R_y(t) = 0$, má jednoduše relativní rychlost $V_x(t) = T_x(t)$ a $V_z(t) = T_z(t)$.

3.3 Extrakce klíčových bodů v reálném čase


Extrakce klíčových bodů je ovlivněna mnoha faktory, a proto může být při určitých situacích obtížná. Samotné oddělení vozidla od pozadí není jednoduché vzhledem ke komplexní povaze scény, která se neustále mění. Ta může obsahovat překrývající se vozidla i velké množství komplikovaných tvarů a textur vozidla i okolí, které ovlivňují extrakci.

Odraz světla od metalických povrchů i zadních oken automobilů a deformované či rozšířené stíny na většině vozidel dělají informaci o tvaru a barvě nespolehlivou.

Pro těchto vlivů jsou vybrány tři typy nízkourovňových klíčových bodů spolehlivých pro detekování vozidel: Detekce rohů, detekce segmentů horizontálních hran a detekce lokálních extrémů intenzit [14].

3.3.1 Detekce rohů

Významnými klíčovými body ve videu jsou rohy objevující se na místech s vysokým kontrastem a velkou křivostí bodů.



Obrázek 3.3: Detekce rohů - Harris corner detection. Po aplikování Harrisova rohového detektoru si můžeme povšimnout, že klíčové body jsou v místech tvořených dynamickým přechodem, a jsou tedy seskupeny kolem vozidel, případně jejich stínů. Dále se klíčové body objevují kolem výrazných hran, v našem případě tvořených protihlukovou zábranou podél dálnice. Malé množství klíčových bodů se může vyskytovat i na statické části pozorovatelského automobilu, v závislosti na světelných podmínkách.


Během dne mají rohové body na povrchu vozidla či pozadí scény stabilní pozice v čase, takže poskytují ucelené pohybové informace. Nicméně na obrysech překrývajících se vozidel (obvykle po obou stranách vozidla), jsou detekované rohové body tvořeny vozidlem a pozadím, které fyzicky neexistuje. Toto pozadí je velice nestabilní během relativního pohybu vozidla a pozadí scény. Pro detekování rohů je použit Harrisův rohový detektor představený ve článku [11]. Výsledky detekce je možno vidět na obrázku 3.3.

Chceme-li definovat pojem rohů v obraze je dobré si popsat, jak vlastně Harrisův detektor funguje. Harrisův detektor zkoumá změny průměrné směrové intenzity v malém okně okolo domnělého bodu zájmu. Budeme-li uvažovat o posunu vektoru (u, v) , průměrná změna intenzity je dána vztahem

$$R = \sum (I(x + u, y + v) - I(x, y))^2. \quad (3.6)$$

Součet probíhá přes okolí definované kolem domnělého pixelu. Tato změna průměrné intenzity může být poté spočítána pro všechny možné směry, což vede k vymezení rohového bodu, pro který je průměrná změna větší ve více jak jednom směru. Podle této definice je zkouška Harrisova detektoru prováděna následovně. Nejprve je získán směr maximální

průměrné změny intenzity, dále se kontroluje, zda je průměrná změna intenzity vysoká také v ortogonálním směru. Pokud ano, jedná se o rohový bod [18].



Obrázek 3.4: Detekce horizontálních úseček. Na obrázku si můžeme povšimnout kumulování úseček kolem automobilu a jeho stínu. Dále pak zachycené horizontální úsečky pozadí, ale i svodidel, které se ve snímku jeví horizontální. Barevnost snímku byla upravena oproti originálu, který se používá při detekci, z důvodu lepší čitelnosti.

3.3.2 Detekce úseček

Po prozkoumání tvarů vozidel si můžeme povšimnout, že jejich zadní části vozidel většinou obsahují více horizontálních hran, které jsou tvořeny střechou, zadním oknem, nárazníky a stínem vozidla. Většina z těchto hran je běžně viditelná během dne, což signalizuje přítomnost vozidla v obraze. Detekce horizontálních úseček je stabilní i pro vozidla s částečně zakrytou zadní částí. Naopak vertikální úsečky nemusí být viditelné. Jsou ovlivněny zakřivením karoserie vozidla, častým zastíněním jiným vozidlem nebo měnícím se pozadím.

Na každý snímek videa je aplikován vertikální diferenciální operátor $\partial I(x, y)/\partial y$, jehož výsledkem je snímek $I'_y(x, y)$. Následně algoritmus vyhledávající hrany hledá lokální extrémy s kontrastem vyšším než je práh δ_1 v obraze $I'_y(x, y)$ pro vytvoření krajních bodů horizontálních úseček. Horizontální prohledávání má vertikální toleranci ± 2 pixely a vybírá takové body, které tvoří náznak stejné hrany. Dále je používán druhý práh $\delta_2 < \delta_1$ pro propojení úseček. Sledované body hran vytvoří úsečku, která má téměř horizontální orientaci. Prahové hodnoty jsou stanoveny tak, aby vytvářely více úseček. Pro další pravděpodobnostní zpracování je lepší podat více informací, než je náhle zavrhnout při detekci.

Sledování úsečky může ztroskotat na odlescích, nedostatečném rozlišení vzdálených au-

tomobilů či změně jejich měřítka. Výsledky mohou také zahrnovat úsečky ve statickém pozadí, jako jsou dráty vysokého napětí, vodorovné dopravní značení, některé typy pouličního osvětlení a struktury některých staveb. Výsledek extrakce úseček je ukázán na obrázku 3.4. Funkce implementující detekci horizontálních úseček je popsána v podsekcí 4.1.

3.3.3 Detekce extrémů intenzit

Lokální extrémů intenzit z předních a koncových světel jedoucích vozidel či pouličního osvětlení jsou použity jako klíčové body za předpokladu, že okolní světelné podmínky jsou špatné. Detekce lokálních extrémů intenzit ze světel vozidla poskytuje další důkaz o výskytu vozidla ve snímku. Pro detekci extrémů intenzit je použit Gaussovský filtr s velkým rozptylem k vyhlazení snímku a následně jsou nalezeny lokální maxima. Extrémy jsou dále sledovány přes další snímky pro získání směru a rychlosti pohybujícího se cíle. Výsledky detekce lze vidět na obrázku 3.5.



Obrázek 3.5: Detekce lokálních extrémů intenzit. Můžeme si povšimnout, že lokální extrémů jsou výrazně jasnější než jejich okolí. Zde se jedná především o koncová světla automobilů a osvětlené registrační značky vozidla. Vydetekované extrémů označeny zeleným obdelníkem.

3.4 Vertikální profilování snímků a klíčových bodů

Aby bylo možné sledovat cíl v reálném čase a získat výsledky odolné vůči chvění vozidla, dochází k urychlení procesu pomocí vertikální projekce intenzity barvy $I(x, y)$ do podoby 1-D profilu $T(x)$ pro každý snímek videa. Tyto po sobě jdoucí profily vytvářejí v průběhu času kondenzovaný časoprostorový obraz $T(x, t)$, představený ve člancích [6] a [28], který

je používán pro analýzu pohybu scény. Vertikální projekce intenzit přes váhovou funkci $w(x, y)$ je implementována jako

$$T(x, t) = \sum_{y=-h/2}^{h/2} w(x, y)I(x, y, t), \quad (3.7)$$

kde h je výška snímku. Váhová funkce, popsána dále v sekci 3.6, je funkce hustoty pravděpodobnosti, která je vysoká v místech s velkou pravděpodobností výskytu vozidla v obraze. Stopy v kondenzovaném časoprostorovém obraze zobrazují pohyb dlouhých a silných vertikálních linek ve videu. Šikmé linky a krátké hrany vyskytující se v jen v ojedinělých video snímcích nebudou v obraze zahrnuty. Obrázek 3.6 nám ukazuje obraz, který je kompaktní reprezentací záznamu a odhadu pohybu vozidla.

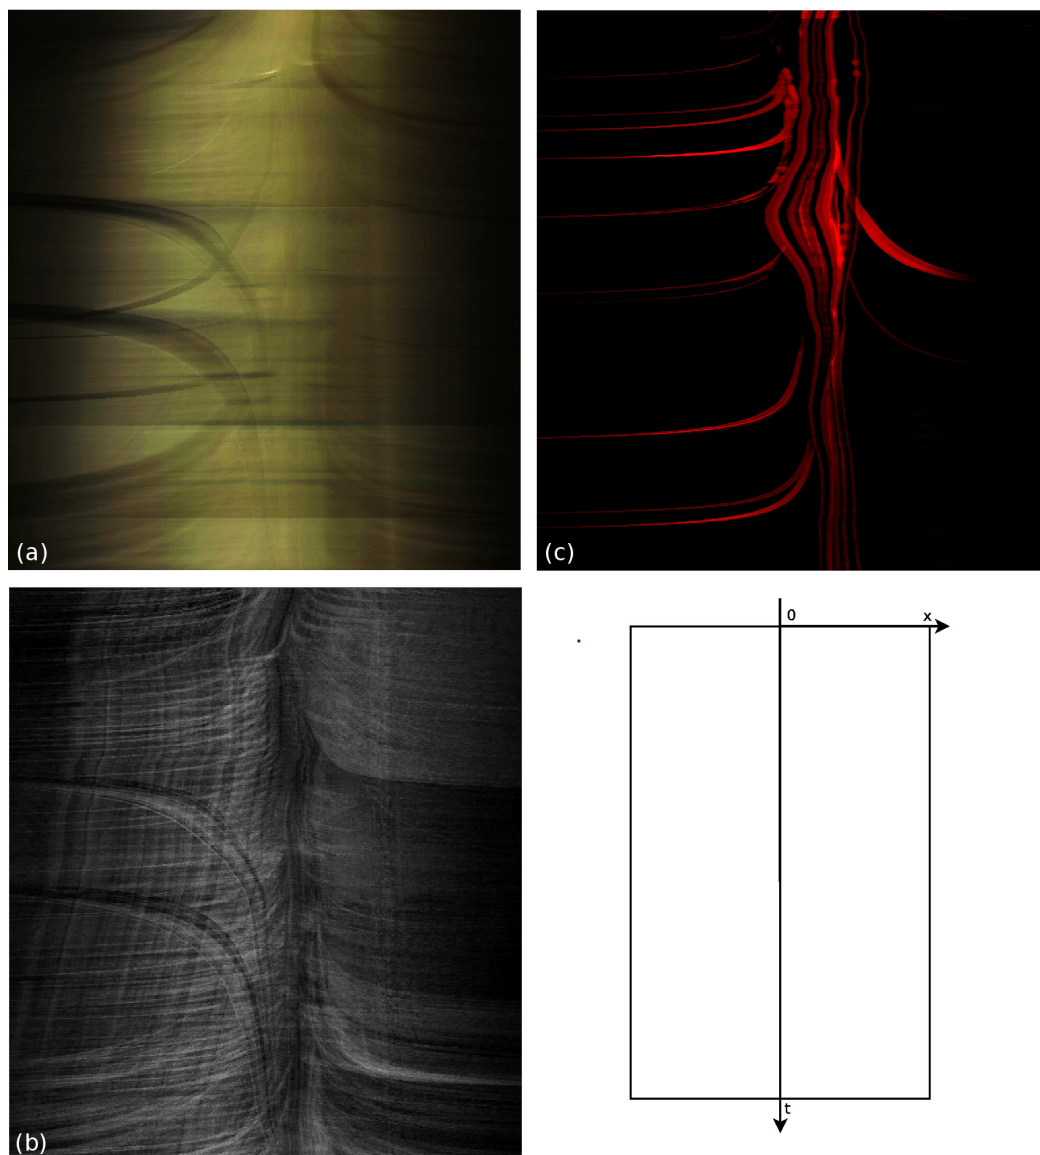
Kromě profilování barevné intenzity snímku dochází také k profilování klíčových bodů extrahovaných ze snímku. Vyprofilované klíčové body vytváří stopy v časoprostorovém obraze. Například dochází k profilování všech horizontálních úseček pro každou pozici x funkcí

$$T_l(x, t) = \sum_{y=-h/2}^{h/2} w(x, y)L(x, y, t), \quad (3.8)$$

kde $L(x, y, t)$ má hodnotu logická 1 (čtyřnásobně zesílená) na detekované úsečce a logická 0 pro všechny ostatní části ve snímku t . Výsledek profilování je možno vidět na obrázku 3.6(b), kde akumulované bílé pruhy značí pohyb vozidla. Dlouhé a horizontální přímky, například vodorovné dopravní značení a dráty, přidávají hodnoty stejně na všech místech bez ovlivnění stop vozidel. Vzhledem k existenci více horizontálních úseček na vozidle se stopy reprezentující pozici vozidla objevují jasnější než jiné, které reprezentují pozadí.

K výrazným změnám v osvětlení scény dochází například při vjezdu do tunelu nebo jeho opuštění, při projíždění lokalit se stínem a osvětlením slunečními paprsky, nebo při osvětlení jinými vozidly. Tyto změny ovlivňují intenzitu celého snímku. V časoprostorovém profilu se změna osvětlení projeví horizontální přímkou přes celou šířku snímku. Tento vliv na polohu vozidla je odfiltrován horizontální derivací profilu.

V porovnání s profily intenzit se souvislými stopami od vertikálních úseček, získáváme profilováním horizontálních úseček šumivé stopy kvůli nestabilitě detekce úseček. Úsečky se nemusejí vždy objevit se stejnou délkou a umístěním, jelikož světelné podmínky, pozadí a šum kamery se liší snímek od snímku. Proto musí dojít k následnému zpracování snímku podle jejich aktuálních souvislostí. Kromě toho se může v obraze objevit více stop, jak je vidět na obrázku 3.6(a), které nemusejí patřit automobilu, ale pozadí, a proto je obraz dále ponechán pro klasifikaci stopy.



Obrázek 3.6: Kondenzovaný časoprostorový obraz. (a) Zobrazuje profil intenzit záběrů z dálnice, kde si můžeme povšimnout stop pozadí směřujících ze středu profilu do stran a také stop automobilů, které směřují naopak ze strany do středu profilu. Vodorovné stopy potom zobrazují přechody mezi světlý a stíny. (b) Zobrazuje profil intenzit horizontálních úseček pro totožnou sekvenci jako (a), stopy automobilů a výrazných prvků pozadí se na profilu jeví výraznější a jasnější. (c) Zobrazuje profil lokálních extrémů intenzit koncových světel automobilu, kdy stopy vedoucí přes celý snímek odpovídají vozidlu jedoucímu před námi. Všechny snímky byly upraveny pro lepší zobrazení a čitelnost pomocí změny úrovní.

3.5 Sledování klíčových bodů

Profil intenzit nám ukazuje horizontální pozice vertikálních klíčových bodů a zanedbává horizontální klíčové body. To vytváří ucelený obraz vhodný pro pochopení horizontálních pohybů ve videu. Profilováním snímků dochází k výraznému potlačení efektu chvění a ná-

klonu kamery při jízdě po nerovných silnicích.

Sledování profilů intenzit se provádí pomocí horizontální diferenciace $T(x, t)$. Hrany jsou označeny v obraze $E(x, t)$ a je nastaveno maximální rozpětí pro po sobě jdoucí body stopy. Zároveň je vypočítáno $\partial T(x, t)/\partial t$ pro zjištění horizontálních hran, protože stopy rychle se pohybujícími objekty jsou v obraze $T(x, t)$ nakloněné. Potom tedy může dojít ke spojení horizontálních hran s hranami v obraze $E(x, t)$. Velmi dlouhé horizontální úsečky v obraze $E(x, t)$, tvořené hlavně změnami osvětlení scény, jsou ve výsledku ignorovány. Nyní jsme schopni z obrazu získat polohu stopy $x(t)$ a její rychlost $v(t) = x(t) - x(t - 1)$.

Pro zachování souvislého pohybu se porovnává rychlost $v(t - 1)$, z již sledovaných bodů obrazu, s rychlostí $v(t)$ nových kandidátů a vybírá se takový následující bod, pro který platí, že $|v(t) - v(t - 1)|$ je minimální. Tento přístup zkoumání souvislosti pohybu se také uplatňuje pro sledování stop v profilu lokálních extrémů intenzit.

Ze všech typů stop, které můžeme získat, poskytuje profil intenzit horizontálních úseček nejzásadnější informaci o přítomnosti vozidla v obraze. Nejprve je provedeno horizontální vyhlazení obrazu $T_l(x, t)$ pro získání hlavních stop. Vrcholy překračující práh jsou označeny jako středy stop $x(t)$. O hodnotě prahu se rozhoduje pro každý čas t na základě průměrné a směrodatné odchylky obrazu $T_l(x, t)$.

Pro získání komplexního řešení zahrnující velké množství stop vozidel a pozadí dochází ke spojení obrazu $T_l(x, t)$ s již spojeným obrazem v $E(x, t)$. Tímto spojením vznikne obraz $T_f(x, t)$. Sledování stop ve výsledném obraze $T_f(x, t)$ je založeno na zjištění středového bodu každé stopy, protože krajní body stopy mohou být nespolehlivé, obzvlášť pro vzdálené vozidlo.

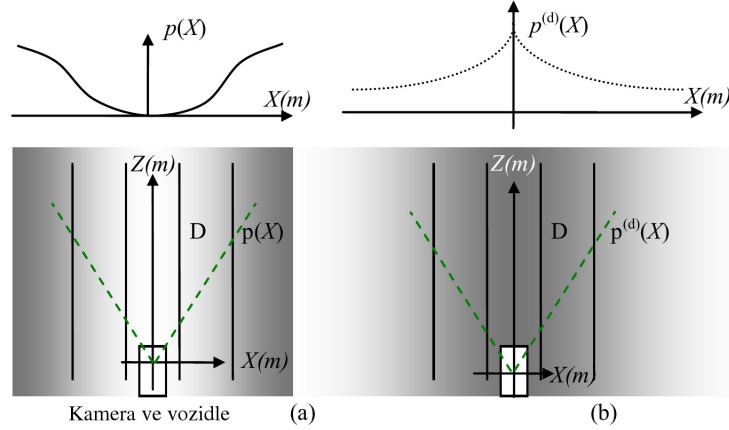
Náhodné úsečky na pozadí a náhlé změny světla působící přes celý snímek způsobí dlouhou horizontální přímku v obraze $T_l(x, t)$ podobně jako přechody mezi světlými a stíny v obraze $T(x, t)$. Nicméně tento jev je eliminován během procesu nalézání vrcholů, jelikož nemají žádný zřetelný vrchol, a dlouhodobého sledování. Pro identifikaci vozidla během dne jsou použity tyto stopy a šířka vozidla je získávána z profilů intenzit. V noci a při zhoršené viditelnosti, jako je mlha či sněžení, mohou být použity profily lokálních extrémů intenzit z brzdových světel.

3.6 Modelování pohybu scény pomocí HMM

Pro zjištění stavu stop objektů sledovaných pomocí skrytých Markovovských modelů (dále jen HMM⁴) je potřeba vytvořit modely pohybů z pravděpodobností. Pro libovolný čas t jsou k dispozici dva skryté stavy: *vozidlo* a *pozadí*, označené jako C_t a B_t . Pozorovány jsou pozice stopy v obraze $x(t)$ a horizontální rychlostní složka stopy $v(t)$ vektoru $u(x, y)$. Běžně užívané HMM, jehož principy lze najít v [7], pracuje s diskrétními událostmi, oproti těmto veličinám, které jsou spojitě. Vektor $(x(t), v(t))$ je získán z každé sledované trajekto-

⁴HMM - Hidden Markov Model

rie v kondenzovaných profilech. Oba parametry jsou na sobě závislé, protože žádný z nich nedokáže identifikovat objekt samostatně. Prvotně jsou vypočítány věrohodnosti jejich spojitých funkcí hustoty pravděpodobnosti $P(x, v|B)$ a $P(x, v|C)$, pro pozadí a vozidlo, aby bylo následně možné určit posteriorní pravděpodobnosti $P(B|(x(t), v(t)))$ a $P(C|(x(t), v(t)))$ na základě pozorování, popsané v sekci 3.7 [14].



Obrázek 3.7: Zobrazuje rozdělení pravděpodobností pozadí mimo silnici. Jeho detekovatelnost je zobrazena tmavší intenzitou. (a) Zobrazuje rozložení klíčových bodů pozadí na okrajích vozovky. (b) Znázorňuje, že detekovatelnost klíčových bodů v městských oblastech klesá, dochází-li k překrývání klíčových bodů blízko silnice. Převzato ze článku [14], obrázek byl upraven.


3.6.1 Funkce věrohodnosti pozadí - přímé cesty

V souřadném systému kamery $O-XYZ$, je X horizontální vzdálenost bodu objektu od středu osy kamery. Pro pozadí platí, že $|X| > D$, kde $2D$ je průměrná šířka silnice. Předpokládejme tedy jeho rozložení pravděpodobnosti v souřadném systému $O-XYZ$, které je zobrazeno na obrázku 3.7(a). Výšky klíčových bodů pozadí jsou homogenně rozptýleny pro zahrnutí vysokých budov a stromů. Za předpokladu celkového posunutí vozidla jako první (tj. $R_y = 0$), absolutní rychlost kamery V (ve směru osy Z) napodobuje Normální rozložení pravděpodobnosti, $p(V) \sim G(S, \sigma^2)$, kde jako střední hodnotu S lze nastavit 50 km/h a směrodatná odchylka může být 10 km/h. Pro bod pozadí tedy platí, že se přibližuje ke kameře, zatímco jeho pozice X je pevná, tedy $V_x = 0$ a $V_z = -V$. Potom se tedy z rovnice rychlosti bodu v obraze (3.3) stane

$$v(t) = \frac{fXV}{Z^2(t)} = \frac{Vx^2(t)}{fX} \quad \text{pro } V > 0. \quad (3.9)$$

Toto vytváří četné křivky funkce v prostoru $(x(t), v(t))$ pro různá X , jak ukazuje obrázek 3.8(a). V případě, že vozidlo má téměř konstantní rychlost, trajektorie tvoří hyperbolu $x(t) = fX/(Z_0 - Vt)$ v profilu $T(x, t)$ od počáteční hloubky Z_0 podle rovnice (3.1). Co se týče rozdělení klíčových bodů pozadí podél osy X , lze předpokládat, že se bude podobat

převrácenému Gaussovskému rozdělení, tj. $p(X) \sim 1 - \exp(-X^2/2D^2)$, jak ukazuje obrázek 3.7(a).



Obrázek 3.8: Vztah pozice a horizontální rychlosti bodu pozadí scény v obraze. (a) Zobrazuje stopy pohybu bodů pozadí na pravé straně vozovky. S klesající hloubkou Z se pozadí pohybuje rychle směrem ven z obrazu. (b) Zobrazuje stopy pozadí po obou stranách vozovky. Barvy odpovídají různým pozicím bodu X z osy kamery. Převzato a upraveno ze článku [14].

Obecně platí, že funkce hustoty pravděpodobnosti náhodné proměnné χ je $p_\chi(\chi)$ a β je monotónní funkce proměnné χ , tj. $\beta = f(\chi)$. Funkce hustoty pravděpodobnosti β může být spočítána jako

$$p_\beta(\beta) = p_\chi(f^{-1}(\beta)) \left| \frac{\partial f^{-1}(\beta)}{\partial \beta} \right| \quad \text{nebo} \quad p_\beta(\beta) = \frac{p_\chi(f^{-1}(\beta))}{\left| \frac{\partial f(\chi)}{\partial \chi} \right|}, \quad (3.10)$$

v souladu s knihou [23]. Skrytý význam těchto vzorců je následující. Za prvé, pro diskrétní náhodné události je hodnota funkce β mapována z proměnné χ . Z tohoto důvodu je výskyt pravděpodobnosti funkce β úplně stejný jako u proměnné χ , tj. $p_\beta(\beta) = p_\chi(\chi)$. Opačné mapování funkce β do proměnné χ lze v této oblasti získat jako $p_\beta(\beta)$ z odpovídající $p_\chi(f^{-1}(\beta))$. Za druhé, pro spojitě funkce f , deriváty $|\cdot|$ v rovnici (3.10) upravují místní rozsah funkce hustoty pravděpodobnosti mezi rozsahem proměnné χ a funkcí β při reprezentování stejné náhodné události. Dále, pro vícerozměrné funkce f , tj. β a χ jsou vektory stejné délky, funkce rozdělení pravděpodobnosti dané funkce může být také odvozena podobně jako $|\cdot|$ v případě, že je změněna do Jacobiho tvaru.

Nyní lze spočítat věrohodnost $p(x, v|B)$ chování pohybu bodu pozadí obrazu $(X, Z) \in B$. Zde jsou původní proměnné X , Z a V ve 3D prostoru a jejich funkce hustoty pravděpodobnosti jsou přednastaveny. Parametry bodu obrazu x a v jsou jejich závislé funkce, jak popisují rovnice (3.3) a (3.9). Protože opačné mapování ze souřadnic x , v do souřadnic X, Z, V není jednoznačná transformace mezi stejným počtem proměnných. Musí se tedy použít Bayesův teorém a podmíněné pravděpodobnosti pro zahrnutí všech možných případů souřadnic X, Z, V při vytváření jejich společných pravděpodobností pro (x, v) . Dochází k mapování dvojice (x, v) na proměnné Z a V ve 3D prostoru ve smyčce přes celou škálu

X , což je podrobně popsáno jako

$$\begin{aligned}
p(x, v|B) &= p(x, v|(X, Z) \in B) & (3.11) \\
&= \int_X p(X)p(x, v|X, (X, Z) \in B)dX & \text{Podmíněná pravděpodobnost} \\
&= \int_X p(X)p(Z(x, v), V(x, v)|X) \\
&\quad \times \left| \frac{fX}{x^2} \right|^2 dX & \text{podle (3.10), (3.1) a (3.9)} \\
&\quad \text{Výměna } p(Z, V) \text{ za } p(x, v) \text{ a výpočet Jacobiho determinantu} \\
&= \int_X p(X)p(Z(x, v)|X)p(V(x, v)|X) \left| \frac{fX}{x^2} \right|^2 dX & Z, V \text{ nezávislé} \\
&= \int_X p(X)p\left(Z = \frac{fX}{x} | X\right) \\
&\quad \times p\left(V = \frac{vfX}{x^2} | X\right) \left| \frac{fX}{x^2} \right|^2 dX & \text{podle (3.1) a (3.9)}
\end{aligned}$$

podle článku [14]. Vzhledem k tomu, že $p(Z)$ je invariantní ve směru osy Z , jak je znázorněno na obrázku 3.7(a), tak může být $p(Z)$ přesunuto před integrál jako konstanta. Původní vstupní rozdělení pravděpodobností proměnných X a V , tedy věrohodnostní funkce hustoty pravděpodobnosti pozadí se změní na

$$\begin{aligned}
p(x, v|B) &= C_b \int_X p(X)p\left(V = \frac{vfX}{x^2} | X\right) \left| \frac{fX}{x^2} \right|^2 dX & \text{podle (3.11)} \\
&= C_b \int_X \left(1 - e^{-\frac{X^2}{2D^2}}\right) e^{-\frac{(\frac{vfX}{x^2} - s)^2}{2\sigma^2}} \left| \frac{fX}{x^2} \right|^2 dX, & (3.12)
\end{aligned}$$


kde C_b je konstanta a Jacobiho determinant je zahrnut. V reálných situacích se dále bere v úvahu detekovatelnost pozadí scény jako funkce $p^{(d)}(X) \propto 1/(|X| + 1)$. Objekty pozadí podél silnici mají nejvyšší viditelnost. Čím dále je objekt od silnice ($|X|$ se zvětšuje), tím větší je šance na to, aby byl překryt objekty v popředí. $p(X)$ upravené pomocí $p^{(d)}(X)$ je potom

$$p(X) = \frac{1 - \exp(-X^2/2D^2)}{1 + |X|}. \quad (3.13)$$


Věrohodnostní funkce hustoty pravděpodobnosti pozadí je tedy

$$p(x, v|B) = C_1 \int_X \frac{1 - e^{\frac{-X^2}{2D^2}}}{|X| + 1} e^{\frac{-(\frac{v f X}{x^2} - s)^2}{2\sigma^2}} \left| \frac{f X}{x^2} \right|^2 dX, \quad (3.14)$$

kde C_1 je normalizační konstanta, tj. $\int_v \int_x p(x, v|B) dx dv = 1$. Poté, co je získáno $p(x, v|B)$, se normalizuje přes celý rozsah pro stanovení konstanty C_1 a je vytvořena funkce hustoty pravděpodobnosti, která je znázorněná na obrázku 3.9. Hodnoty jsou uloženy do tabulky pro použití při sledování a pro výpočty pomocí HMM⁵ v reálném čase [14].




Obrázek 3.9: Rozdělení pravděpodobnosti pozadí $p(x, v)$ na základě pohybu. Z obrázku lze vyčíst, že body pohybující se velmi rychle a velmi pomalu jsou zohledňovány jako pozadí. Naopak body pohybující se konstantní rychlostí jsou zohledněny jako vozidla. Obrázek byl převzat ze článku [14].



Obrázek 3.10: Přidání složky rotace k pohybu pro vyrovnání zakřivení cesty. (Vlevo) Zobrazuje rozložení pravděpodobnosti $p(x, v)$ pohybu kamery. (Uprostřed) Zobrazuje pohybovou složku ovlivněnou rotací z řízení vozidla. (Vpravo) Zobrazuje posunutí rozložení $p(x, v)$ pohybu zahrnující rotaci, které vytváří nové rozložení. Obrázek byl převzat ze článku [14] a upraven.

⁵HMM - Hidden Markov Model



Obrázek 3.11: Rozložení věrohodnostní funkce hustoty pravděpodobnosti $p(x, v|B)$. Velký důraz je kladen na hodnoty objevující se po okraji spektra osy x a v . Tyto body pohybující se velice rychle, ba naopak pomalu odpovídají pozadí. Pravý dolní a levý horní kvadrant obsahuje velice malé hodnoty, jelikož mohou nastat situace, kdy pozorovatelské vozidlo předjíždí jiné vozidlo, nebo je naopak předjížděno, a ty tyto případy nesmíme zahrnout do klasifikace pozadí.

3.6.2 Funkce věrohodnosti pozadí - točité cesty

Při plynulé jízdě pozorovatelského vozidla po rovných a mírně točitých silnicích by mělo docházet jenom k malým změnám v řízení. Otáčení vozidla $R_y(t)$ můžeme popsat pomocí Normálního rozdělení s malým rozptylem. Podle rovnic (3.4) a (3.5) lze odhadnout obecné rozložení $p(x, v)$ včetně rotace díky přidání složky $v^{(r)}(t)$ k rychlosti obrazového bodu, která byla prozatím tvořena pohybem $v^{(t)}(t)$. Jedná se o vertikální posunutí $p(x, v)$ z bodu $v^{(t)}(t)$ o člen $v^{(r)}(t)$ ve kvadratickém tvaru, jak zobrazuje obrázek 3.10. Aktualizovaný rozsah trajektorií klíčových bodů je pro určitý úhel natočení řízení R_y zobrazen na obrázku 3.10. Pokud kódovací zařízení pozorovatelského auta neposkytuje parametr natočení $R_y(t)$, musí dojít k zahrnutí všech možných hodnot $R_y(t)$ do normálního rozložení, pro vypočítání $p(x, v|B)$ jako


$$\begin{aligned}
 p(x, v|B) &= \int_{R_y} p(R_y) p(x, v|R_y) dR_y & (3.15) \\
 &= \int_{R_y} p(R_y) p\left(x, v|v = \frac{x^2 V}{fX} - \frac{x^2 + f^2}{f} R_y\right) dR_y & \text{rovnice (3.4)} \\
 &= C_{1r} \int_{R_y} \int_X e^{\frac{-R_y^2}{2\sigma_r^2}} \frac{1 - e^{\frac{-X^2}{2D^2}}}{|X| + 1} e^{\frac{-\left(\left(v + \frac{x^2 + f^2}{f} R_y\right) \frac{fX}{x^2} - s\right)^2}{2\sigma^2}} \left|\frac{fX}{x^2}\right|^2 dX dR_y,
 \end{aligned}$$

kde C_{1r} je konstanta a stanoví se normalizací $p(x, v|B)$.

Z důvodů nepřítomnosti informací o natočení vozidla, které použitá kamera není schopna zjistit, byly obě funkce věrohodnosti pozadí spojeny do jedné komplexní funkce, reprezentující dvoudimenzionální Gaussovu křivku, aby bylo možné obsáhnout rozmanité množství různých druhů cest a různých rychlostí vozidel na silnici i vozidla pozorovatelského. Přepočítaná věrohodností funkce hustoty pravděpodobnosti má tedy tvar

$$p(x, v|B) = C_1 \frac{1}{2\pi\sigma_{motion}^2} e^{-\left(\left(\frac{v}{380}\right)^2 + \left(\frac{x}{90}\right)^2\right)} \frac{1}{2\sigma_{motion}^2}, \quad (3.16)$$

kde C_1 je normalizační konstanta a hodnoty v a x jsou nejprve přepočítány s korektním posunutím a rotací. Výsledné rozložení pravděpodobnosti lze vidět na obrázku 3.11. Podrobné rozebrání výpočtu lze potom najít v sekci 4.1.



Obrázek 3.12: Hustota pravděpodobnosti pozice cílového vozidla ve vztahu ke kameře, zobrazená v intenzitách. Tmavší intenzita odpovídá vyšší pravděpodobnosti výskytu vozidla. (a) Zobrazuje rozložení pravděpodobnosti cíle z nadhledu. (b) Znázorňuje projekci rozložení do snímku obrazu. (c) Zobrazuje rozložení pravděpodobnosti klíčových bodů vozidla v závislosti na jeho výšce. Osa Y směřuje dolů kvůli propojení s osou Z , která směřuje dopředu. Převzato ze článku [14] a upraveno.

3.6.3 Pravděpodobnost pohybu hledaného vozidla v obraze

Předpokládáme-li čistý pohyb pozorovatelského vozidla, jak je zobrazeno na obrázku 3.12, lze pomocí pozice cílového vozidla $(X(t), Z(t))$ na cestě ve 3D prostoru odvodit následující 2D Normální rozdělení $G((0, F), (D^2, (2F)^2))$, kde F je jeho průměrná vzdálenost od kamery. V tomto případě $X(t)$ a $Z(t)$ jsou nezávislé a D a $|2F|$ jsou použity jako směrodatné odchylky. Projekce Normálního rozdělení do snímku obrazu je ukázáno na obrázku 3.12(b), který je rozdělený vertikálně do válce podle rozdělení pravděpodobností $H(Y)$ výšky klíčových bodů vozidla, jak lze vidět na obrázku 3.12(c). Ve směru osy Y je garantováno, že klíčové body budou detekovány v blízkosti povrchu země. To je zaručeno vysokým kontrastem nárazníků, pneumatik a stínu vozidla oproti homogennímu povrchu země. Nicméně, klíčové body nemusí být spolehlivě nalezeny pro vyšší pozici Y z důvodů nízké výšky cílového vozidla, odleskům metalického povrchu či zadního okna vozidla. U automobilu šedé

či stříbrné barvy hrozí splynutí barvy střechy s barvou oblohy. Nyní je potřeba navrhnout funkci rozložení klíčových bodů pro pozice Y jako $p(Y) \sim (Y + 3)/(Y + 4)$ v souřadnicovém systému $O-XYZ$, kde $Y \in [-3\text{m}, 1\text{m}]$ za předpokladu, že osa Y směřuje dolů a pozice kamery ve vozidle, kde ($Y = 0$) je 1 metr nad zemí, pro kterou platí ($Y = 1\text{m}$). Kromě toho se předpokládá, že relativní rychlost cílového vozidla ke kameře, označená jako (T_x, T_z) , rovněž vyplývá z Normálního rozložení $G((0, 0), (\sigma_x^2, \sigma_z^2))$ během doby sledování, kde T_x a T_z jsou nezávislé

Pro sledované vozidlo lze tedy spočítat chování bodu v obraze $p(x, v|C)$ podle rovnic (3.1) a (3.3) jako

$$\begin{aligned}
 p(x, v|C) &= p(x, v|(X, Z, T_x, T_z) \in C) \\
 &= \int_Z p(Z) p\left(x = \frac{fX}{Z}, v = \frac{fT_x - xT_z}{Z} | Z\right) dZ \\
 &= \int_Z p(Z) p\left(X = \frac{xZ}{f} | Z\right) \left\{ \int_{T_z} p(T_z) p\left(T_x = \frac{Zv + xT_z}{f} | T_z, Z\right) dT_z \right\} \\
 &\quad \times \left| \frac{Z}{f} \right|^2 dZ.
 \end{aligned} \tag{3.17}$$

Bayesova věta

Doplněním rozdělení pravděpodobností $p(T_x)$, $p(Z)$ a $p(T_z)$, lze získat $p(x, v|C)$ jako

$$\begin{aligned}
 p(x, v|C) &= C_2 \int_Z \int_{T_z} e^{\frac{-(Z-f)^2}{2(2F)^2}} e^{\frac{-(\frac{xZ}{f})^2}{2D^2}} e^{\frac{-T_z^2}{2\sigma_z^2}} e^{\frac{-(\frac{Zv+xT_z}{f})^2}{2\sigma_x^2}} \left| \frac{Z}{f} \right|^2 dT_z dZ \\
 &= C_2 \int_Z \int_{T_z} e^{\frac{-(Z-f)^2}{2(2F)^2} - \frac{-(\frac{xZ}{f})^2}{2D^2} - \frac{-T_z^2}{2\sigma_z^2} - \frac{-(\frac{Zv+xT_z}{f})^2}{2\sigma_x^2}} \left| \frac{Z}{f} \right|^2 dT_z dZ,
 \end{aligned} \tag{3.18}$$


kde C_2 je normalizační konstanta, tj. $\int_v \int_x p(x, v|C) dx dv = 1$. Kromě toho, věrohodnostní funkce hustoty pravděpodobnosti obsahující natočení pozorovatelského vozidla může být odvozena podobně jako rovnice (3.15).

$$\begin{aligned}
 p(x, v|C) &= \int_{R_y} p(R_y) \int_Z p(Z) p\left(X = \frac{xZ}{f} | Z\right) \\
 &\quad \times \left\{ \int_{T_z} p(T_z) p\left(T_x = \frac{Zv + xT_z}{f} + \frac{x^2 + f^2}{f} Z R_y | T_z, Z, R_y\right) \left| \frac{Z}{f} \right|^2 dT_z \right\} dZ dR_y.
 \end{aligned} \tag{3.19}$$

Pro zjednodušení výpočtu a pokrytí většího rozptylu rychlostí a většího množství situací, byla původní věrohodnostní funkce hustoty pravděpodobnosti převedena do tvaru

$$p(x, v|C) = C_2 \frac{1}{2\pi\sigma_{motion}^2} e^{-\left(\left(\frac{x}{640}\right)^2 + \left(\frac{v}{50}\right)^2\right)} \frac{1}{2\sigma_{motion}^2}, \quad (3.20)$$

který poskytuje téměř totožný rozsah rozdělení pravděpodobnosti jako původní funkce, avšak má strmější vzestup. C_2 je normalizační konstanta a funkce reprezentující dvoudimenzionální Gaussovu křivku má rozdělení pravděpodobnosti soustředěné kolem osy x , jak lze vidět na obrázku 3.13.



Obrázek 3.13: Rozložení věrohodnostní funkce hustoty pravděpodobnosti $p(x, v|C)$. Z obrázku lze vyčíst, že je kladen velký důraz na body pohybující se téměř konstantní rychlostí, podél celé osy x .

3.6.4 Výskyt hledaných vozidel v obraze

Vertikální profilování klíčových bodů a intenzity snímků zjednodušuje sledování cíle. Aby bylo možné lépe získat informace o pohybu cílových vozidel z časoprostorového obrazu, je nutno vytvořit váhovou masku snímku, která se bude dále používat při profilování. S využitím stejné funkce hustoty pravděpodobnosti vozidla, jako v předchozí sekci 3.6, dochází k vypočítání pravděpodobnosti výskytu klíčových bodů pro každou pozici v obraze, tj. $p(x, y|C)$ nebo zjednodušené váhové funkce $w(x, y)$. Protože mapování ze souřadnic X, Y, Z do souřadnic x, y není ve vztahu 1 : 1, pravděpodobnost $p(x, y|C)$ se tedy vypočítá jako


$$\begin{aligned} p(x, y|C) &= \int_Z p(Z) p(x, y|Z) dZ \\ &= C_3 \int_Z e^{\frac{-(Z-F)^2}{2(2F)^2}} e^{\frac{-(\frac{xZ}{f})^2}{2D^2}} \frac{yZ + 3f}{yZ + 4f} \left| \frac{Z}{f} \right|^2 dZ, \end{aligned} \quad (3.21)$$

kde C_3 je normalizační konstanta.

Z důvodu rozdílné kalibrace kamery v originálním návrhu a v této práci, bylo nutné tuto rovnici přepočítat, protože by kvůli rozdílné poloze horizontu ve směru osy snímku y docházelo k eliminaci klíčových bodů místo ignorování prvků pozadí. Jak je vidět na obrázku 2.1, vozidla se vyskytují zejména v dolní polovině snímku. Proto byla rovnice zjednodušena a upravena do tvaru

$$p(x, y|C) = C_3 \frac{1}{2\pi\sigma_{car}^2} e^{-\frac{(\frac{x}{11})^2 + (\frac{y}{4})^2}{2\sigma_{car}^2}}, \quad (3.22)$$

kde C_3 je normalizační konstanta a rovnice, reprezentující dvoudimenzionální Gaussovu křivku, byla posunuta ve směru osy y tak, aby lépe odpovídala možnému výskytu vozidel. Výsledek rozdělení pravděpodobnosti této funkce můžete vidět na obrázku 3.14. Funkce je poté použita během profilování v rovnicích (3.7) a (3.8) jako $w(x, y)$, aby usnadnila extrakci vozidel a ignorovala větší část nepodstatných prvků pozadí. Tyto prvky se nacházejí zejména v horní polovině snímku, jak bylo možné vidět na snímku 2.1, kdy je minimálně horní polovina snímku zaplněna oblohou, popřípadě obsahuje stavby, jak je tomu při jízdě městem.




Obrázek 3.14: Váhová maska $w(x, y)$ pro profilování snímku. Důraz je kladen zejména na dolní polovinu snímku, kde se mohou vyskytovat vozidla. Horní polovina snímku je má jenom velmi malý vliv na vytváření kondenzovaných profilů. V této části snímku se nejvíce vyskytuje obloha a statické pozadí.

3.7 Identifikace vozidla na základě pohybu

Pro klasifikaci stopy na automobil či pozadí lze využít sledování její trajektorie po určité době, díky čemuž bude metoda schopna identifikovat stopu s určitou pravděpodobností.

Klasifikace se provádí výpočtem pravděpodobností v každém okamžiku pomocí HMM⁶, představeného v sekci 3.6, na základě sekvencí vektorů (x, v) . Průběžným sledováním stop se dále zvyšuje důvěra v rozhodnutí. Formulováním problému s klasifikací pomocí pravděpodobností, lze zabránit hromadění nelineárních rozhodnutí z více prahů při segmentaci a sledování, a tím zlepšit kvalitu identifikace vozidel [14].



Obrázek 3.15: Trajektorie chování pohybu vozidel a pozadí v průběhu času. Zobrazené trajektorie jsou zobrazeny v pozici a zakřivení vzhledem ke kameře. Na obrázku je vidět, jak se liší trajektorie pro blízké a vzdálené pozadí. Dále jsou zde ilustrovány různé typy trajektorií pro pohyb vozidla v obraze. Obrázek byl převzat ze článku [14] a patřičně upraven.

3.7.1 Chování pohybu scény v různých stopách

Pro identifikaci vozidla jsou hlavním důkazem o přítomnosti vozidla jeho pohybové vlastnosti v časoprostorovém obraze. Pohyb pozadí je určen pohybem kamery a jeho vzdáleností. Dočasný kondenzovaný obraz složený z 1D profilů získáme posunem kamery s čelním pohledem ve směru osy Z . V takové časoprostorové reprezentaci ilustrované obrázkem 3.15 je možné pozorovat hyperbolické dráhy pozadí rozpínající se směrem od FOE⁷.

1. Klíčové body se svou přibývajícím rychlostí pohybují v zobrazení do boku.
2. Zakřivení trajektorie je vysoké pro objekty poblíž silnice a nízké pro objekty vzdálené od silnice.
3. Klíčové body vozidla přijíždějícího do záběru se pohybují do středu zobrazení
4. Rychlost bodů $(v(t))$ je úměrná jejich pozici $x(t)$.

⁶HMM - Hidden Markov Model

⁷FOE - Focus of expansion - Bod ve středu horizontu, ze kterého se zdá že vychází všechny pohyb. Průsečík optických toků.

Rychlost bodů je vysoká, pokud kolem těchto bodů jenom projíždíme a nízká pro body, které jsou před námi. Na druhou stranu, vozidla sledována na cestě mohou zůstat v obraze i za předpokladu, že jedou nepravidelně a kličkují ze strany na stranu.

3.7.2 Počítání posteriorních pravděpodobností

Po získání pravděpodobností $p(x, v|B)$ a $p(x, v|C)$ do dvou tabulek je možno přistoupit k identifikaci klíčových bodů na základě informací dostupných o chování jejich pohybu. Posteriorní pravděpodobnosti zkoumaného stavu $(x(t), v(t))$, jsou označeny jako $P(C_t|x(t), v(t))$ a $P(B_t|x(t), v(t))$ v tomto pořadí, nebo zkráceně $P(C_t)$ a $P(B_t)$. Pro každý čas t musí zůstat

$$P(C_t) + P(B_t) = 1. \quad (3.23)$$

Pravděpodobnost přechodu mezi stavy ze snímku $t - 1$ do snímku t je definovaná jako

$$\begin{aligned} P(C_t|B_{t-1}) &= 0.5 & P(B_t|B_{t-1}) &= 0.5 \\ P(C_t|C_{t-1}) &= 0.8 & P(B_t|C_{t-1}) &= 0.2 \end{aligned} \quad (3.24)$$

Přechod z automobilu do automobilu, tj. $P(C_t|C_{t-1}) = 0.8$ klade důraz na kontinuitu pohybu automobilu, tedy jakmile je automobil jednou detekován, nebude jej možné snadno přehlédnout. Stopa dříve identifikovaná jako pozadí může být jako automobil identifikována později, tj. $P(C_t|B_{t-1}) = 0.5$. A to z důvodu, že nemusíme mít k dispozici dostatečně silný zachytný bod k rozhodnutí, že se jedná o automobil, hlavně v oblasti FOE, kde body pozadí i vozidla mají nízkou rychlost. Když je detekována trajektorie ($t = 0$), jsou inicializační hodnoty pravděpodobnosti automobilu a pozadí empiricky nastaveny jako $P(C_0) = 0.7$ a $P(B_0) = 0.3$ na základě zjistitelnosti klíčových bodů vozidla ve vážené oblasti obrazu. Použitím Viterbiho algoritmu ze článku [7] v HMM je věrohodnost pro klasifikaci stopy jako automobilu pro čas t optimalizována jako

$$\begin{aligned} P(C_t) &= \max [P(B_{t-1})P(C_t|B_{t-1})p(x(t), v(t)|C_t), \\ &\quad P(C_{t-1})P(C_t|C_{t-1})p(x(t), v(t)|C_t)]. \end{aligned} \quad (3.25)$$

Následně věrohodnost pro klasifikaci jako pozadí je

$$\begin{aligned} P(B_t) &= \max [P(B_{t-1})P(B_t|B_{t-1})p(x(t), v(t)|B_t), \\ &\quad P(C_{t-1})P(B_t|C_{t-1})p(x(t), v(t)|B_t)]. \end{aligned} \quad (3.26)$$

Je-li $P(C_t) > 0.7$, stopa v daném čase t je považována za automobil, jinak za pozadí. Zde došlo ke změně původního návrhu, kdy bylo stanoveno, že jako automobil jsou identifikovány stopy s pravděpodobností $P(C_t) > P(B_t)$. Identita stopy je zobrazena po určité době, kdy je stopa sledována a předpokládá se, že cílové vozidlo rychle nezmizí ze zorného pole. V opačném případě jsou velice krátké stopy jsou odstraněny jako šum. Pro každou novou stopu vzniká nový HMM. Vypočtená identita stopy může být ze začátku neurčitá vzhledem k nedostatku informací o existenci. Věrohodnost vzrůstá s neustálou aktualizací a sledováním stopy.

Během sledování všech stop v profilech při pohybu vozidla je HMM aplikován na každou stopu pro aktualizaci jejího stavu, tj. automobil nebo pozadí. V každém okamžiku jsou získané posteriorní pravděpodobnosti stop $P(B|(x, v))$ a $P(C|(x, v))$ normalizovány jako

$$P(C_t) \leftarrow \frac{P(C_t)}{P(C_t) + P(B_t)}, \quad P(B_t) \leftarrow \frac{P(B_t)}{P(C_t) + P(B_t)}, \quad (3.27)$$

aby se zabránilo rychlému klesání hodnot $P(C_t)$ a $P(B_t)$ k nule v rovnicích (3.25) a (3.26), které je způsobeno vynásobením řady pravděpodobností hodnotou menší než 1.

Kapitola 4

Implementace a vyhodnocení

Tato kapitola popisuje implementaci metody, její testování a vyhodnocení.

Implementace je rozdělená na dvě fáze. V první fázi bylo důležité vytvořit model vozidla a pozadí a jejich odpovídající funkce hustoty pravděpodobnosti, jejichž hodnoty se budou používat dále. Ve druhé fázi bylo nutno vytvořit aplikaci, která bude dynamicky detekovat a sledovat vozidla. Implementace je popsána v sekci 4.1.

Metoda byla testována na videosekvencích obsahující rozmanité dopravní scény a situace za různých povětrnostních podmínek. Podrobný popis testování je uveden v sekci 4.2.

Vyhodnocením metody se poté zabývá sekce 4.3, která popisuje úspěšnost metody a limitní situace, se kterými se můžeme při aplikování této metody setkat.

4.1 Implementace

Implementace metody probíhala v programovacím jazyce C++ s využitím volně dostupné knihovny pro počítačové vidění OpenCV ve verzi 2.4.4 v integrovaném vývojovém prostředí Qt Creator verze 2.6.2, které je založené na Qt 5.0.1. Pravděpodobnostní mapy byly počítány offline pomocí matematického nástroje Matlab.

4.1.1 Vytvoření pravděpodobnostních map

Pro úspěšnou detekci a sledování automobilu se neobejdeme bez funkcí hustoty pravděpodobnosti, neboli pravděpodobnostních map, které jsou používány jak při vertikálním profilování snímku a klíčových bodů, tak i pro klasifikaci stopy pomocí HMM¹. Jak bylo zmíněno výše, tyto mapy jsou počítány pomocí matematického nástroje Matlab.

V této části bylo nutné implementovat rovnice (3.16), (3.20) a (3.22), které byly uvedeny v kapitole 3. Všechny tyto rovnice představují dvoudimenzionální Gaussovu funkci. Důležitým aspektem jsou použité koeficienty a vstupní hodnoty, které lze najít v tabulce 4.1. U některých funkcí docházelo k posunutí a rotaci, z důvodu vytvoření odpovídajícího

¹HMM - Hidden Markov Model

rozložení. Funkce byly počítány v cyklech a výsledky pro každý cyklus ukládány do matice. Po skončení výpočtů bylo nutné provést normalizaci hodnot, které byly následně vypsány do souborů ve formě tabulek.

Proměnná	Význam proměnné	Hodnota/Rozsah hodnot
x	souřadnice snímku	-320:320
y	souřadnice snímku	-240:119
v	rychlost bodů	-320:320
α	úhel rotace	120°
σ_{car}^2	rozptyl hodnot	500
σ_{motion}^2	rozptyl hodnot	1

Tabulka 4.1: Tabulka koeficientů a vstupních hodnot funkcí pro výpočet v Matlabu.

Věrohodnost pohybu pozadí

Nejprve bylo nutné vytvořit pravděpodobnostní mapu pohybu pozadí v obraze pomocí rovnice (3.16). Aby výsledek splňoval požadavky, bylo zapotřebí vstupní hodnoty počítat s určitým posunutím a rotací. Úhel rotace α byl neměnný, ale posunutí se lišilo pro různé kvadranty. Proto byly vstupní hodnoty přepočítány dvakrát a matice s výsledky posunutých a rotovaných funkcí poté sečteny. Nejprve se počítalo s posunutím $v = v + 320$ a $x = x + 320$, a následně s posunutím $v = v - 320$ a $x = x - 320$. Hodnoty této funkce jsou uloženy v souboru `likelihood_pxB.txt`, v adresáři `carDetection/src/`. Zdrojový kód výpočtu je k dispozici v adresáři `carDetection/matlab/`, v souboru `computation_pxB.txt`.

Věrohodnost pohybu vozidla

Rozložení pravděpodobností funkce reprezentující rovnici (3.20) se kumuluje podél osy x , kde střed je v bodě $v = 0$. Z toho důvodu nebylo nutné provádět žádné posunutí ani rotaci. Hodnoty této funkce lze najít v tabulce uložené v souboru `likelihood_pxC.txt`, v adresáři `carDetection/src/`. Výpočet je potom k dispozici v adresáři `carDetection/matlab/`, v souboru `computation_pxC.txt`.

Výskyt vozidel v obraze - váhová funkce

Rovnice (3.22) se za normálních okolností rozprostírá podél osy x se středem v bodě $y = 0$. Jelikož bylo potřeba dostat rozložení do úrovně odpovídající výskytu automobilů ve snímku, bylo nutné omezit rozsah vstupních hodnoty y tak, aby platilo $y < \text{frame.height}$. Vypočtené hodnoty byly poté ukládány do matice s posunutím $y = y + 120$. Kompletní výpočet je k dispozici v souboru `computation_carProb.txt`, v adresáři `carDetection/matlab/`. Tabulka hodnot funkce je potom dostupná v souboru `carProb.txt`, v adresáři `carDetection/src/`.

4.1.2 Implementace detekční metody

Tělo vlastní aplikace se skládá z několika tříd, které jsou mezi sebou náležitě propojeny. Jedná se o třídy `VideoProcessor`, `carTracker`, `HarrisDetector` a `HMM`.

Třída `VideoProcessor`

O zpracování videosekvencí se stará třída `VideoProcessor`, která byla naimplementována podle knihy [18]. Tato třída obsahuje všechny potřebné metody pro práci s videosekvencemi, jako je například otevření vstupního a výstupního souboru, pojmenování oken a zobrazení vstupní i výstupní videosekvence, nastavení rychlosti snímkování, odezvy, procesoru na zpracování jednotlivých snímků, spuštění a ukončení zpracování sekvence atd. Třída také obsahuje implementaci třídy `FrameProcessor`, která obsahuje virtuální metodu `process()`.

Třída `HarrisDetector`

Detekci rohů v obraze a tedy získáním klíčových bodů se zabývá třída `HarrisDetector`. Implementace této třídy byla provedena dle knihy [18]. Třída obsahuje veškeré metody potřebné pro práci s Harrisovým detektorem. Nejdůležitější metody pro použití při extrakci klíčových bodů ze snímků jsou metody `detect()`, `getCorners()` a `drawOnImage()`.

Metoda `detect()` má jako vstup matici s šedotónovým obrazem a provádí výpočet Harrisových hodnot pro následnou detekci rohů.

K vlastní detekci rohů dochází v metodě `getCorners()`, které je jako první parametr předán seznam pro uložení pozice rohů a jako druhý je předávána požadovaná úroveň kvality detekce.

Poslední z trojice, metoda `drawOnImage()`, se zabývá vykreslováním pozic extrahovaných rohů. Jako vstupní parametr jí je předána matice obsahující snímek, kam chceme body zobrazit.

Třída `carTracker`

Srdce celé aplikace tvoří třída `carTracker`, která je potomkem třídy `FrameProcessor`. Tato třída zajišťuje veškeré kroky potřebné k detekci a sledování vozidel. Jedinou viditelnou metodou této třídy je reimplementovaná virtuální metoda `process()`, které jsou jako parametry předány matice vstupního a výstupního obrazu. V těle metody poté dochází k vytvoření šedotónového obrazu, kopii vstupního obrazu do obrazu výstupního a následně k extrakci klíčových bodů pomocí metody `extractFeatures()`, a ke sledování objektů v obraze pomocí metody `track()`. Metoda `rollCondensed()` slouží k hlídání čítače snímků matic obsahujících kondenzované profily, které pracují na principu kruhového bufferu.

- `extractFeatures()`

Metodě `extractFeatures()` je předáván pouze jeden parametr, a to matice se vstupním obrazem. V těle této metody dochází k extrakci klíčových bodů a různým úpravám snímku nutným pro tuto extrakci a také vytvoření kondenzovaných snímků metodou `createCondensedProfiles()`.

Rohy jsou extrahovány za pomoci instance Harrisova detektoru a před detekcí nepotřebují žádné další úpravy. Lokální extrémní intenzity jsou detekovány ze šedotónového snímku, který je nejdříve rozostřen pomocí funkce `GaussianBlur()` a na tento výstup je poté použita funkce `threshold()`, pro kterou byla zvolena hodnota prahu 140. Před detekcí horizontálních úseček, o kterou se stará metoda `edgeDetection()`, která bude uvedena níže, je zapotřebí na vstupní šedotónový obraz aplikovat Sobelův operátor ve směru osy y a následně vytvořit dva snímky, které vzniknou prahováním výstupu Sobelova operátoru. Po důkladném testování byly zvoleny hodnoty dvou prahů jako 210 a 235. Parametry Sobelova operátoru pak byly nastaveny následovně `ksize = 3`, `scale = 0.5`, `delta = 130`.

- `edgeDetection()`

Metoda `edgeDetection()` slouží k vyhledávání horizontálních úseček ve snímku. Vstupními parametry této metody jsou dvě matice, které vznikly prahováním vstupního snímku a výstupním parametrem je potom matice nesoucí detekované úsečky.

Metoda jako první prohledá matici vytvořenou prahováním s vyšší hodnotou, která obsahuje krajní body úseček a uchová si veškeré získané body. Prohledávání v ose y začíná od hodnoty 120, jelikož vrchní část snímku patří pozadí, a proto ji lze ignorovat. Z uložených hodnot jsou odstraněny osamostatněné pixely, které nemají svůj protějšek v toleranci ± 2 pixely.

Následně dochází k prohledávání matice vytvořené prahováním s nižší hodnotou, které slouží jako propojení bodů získaných z první matice. Body jsou propojeny a matice obsahující horizontální úsečky je vrácena jako výstupní parametr.

- `createCondensedProfiles()`

Tato metoda se stará o vytváření kondenzovaných profilů snímků a klíčových bodů. Parametrem metody je vstupní snímek videosekvence. V těle této metody se využívá metody `transformToCondensed`, která je implementací rovnice (3.7) resp. (3.8). Postupně zde dochází k úpravám snímků, obsahující klíčové body nebo např. vstupní obraz, a k vytváření kondenzovaných profilů těchto snímků.

Nejprve je vytvořen kondenzovaný profil intenzity snímků, následně pak profily vertikálních a horizontálních hran v těchto snímcích spojených do jednoho profilu, který je nakonec zkombinovaný s vytvořeným profilem horizontálních úseček. Tato trojkombinace slouží jako vstupní parametr metody `track()`, popsané níže.

Jsou zde také vytvořeny profily dalších klíčových bodů, jako jsou detekované rohy nebo lokální extrémní intenzity.

- `track()`

Metoda `track()` dostává dva parametry. Jedním z nich je kondenzovaný profil obsahující stopy a tím druhým je výstupní obraz. Tato metoda vyhledává stopy v kondenzovaných profilech, vytváří a aktualizuje instance třídy `HMM` a zajišťuje vykreslování těch instancí, které detekují vozidlo. Metoda nejprve všechny instance detektorů upozorňuje, že dojde k aktualizaci jejich hodnot. Poté iteruje přes všechny souřadnice x a vyhledává v kondenzovaném profilu body o souřadnicích $(indexY, x)$, jejichž intenzita je rovna nule, tj. vyskytuje se zde stopa. Hodnota `indexY` je určena jako aktuální profilovaný snímek videa, jehož hodnota je obsažena v proměnné `frameCounterCondensed`, dekrementována o 1. K dekrementaci hodnoty dochází vzhledem k používání Sobelova operátoru a funkce `threshold` na kondenzovaný profil pro získání stop. Kvůli funkci `threshold` nejsou stopy pro aktuální snímek viditelné, jelikož v profilu prozatím neexistuje následující snímek a tedy jej nelze porovnat a získat hranu.

Narazí-li algoritmus na stopu, zjistí její šířku, otestuje zda již není zpracovávána a za předpokladu že není, vytvoří novou instanci detektoru na prostřední bod stopy. Je-li objevená stopa již zpracovávána, dojde k aktualizaci hodnot instance, která ji zpracovává.

Následně dochází k testování, zda všechny instance byly aktualizovány. V případě že ne, nastavuje se těmto instancím příznak ztráty stopy a tím dochází k jejich přepnutí do režimu predikce pohybu. Nejsou-li jim během následujících deseti snímků aktualizovány hodnoty, jsou tyto instance zrušeny. Podrobnější informace lze nalézt níže.

Nakonec dochází k testování instancí detektorů, zda-li nedošlo k identifikaci některé stopy jako cílového vozidla. Z takového detektoru je následně získána jeho aktuální pozice a uložena do seznamu, který je následně vykreslen metodou `drawTargets()`

Metoda `drawTargets()` požaduje jako parametry matici obsahující snímek videa určený na výstup a seznam souřadnic x , reprezentující pozice detekovaných vozidel. Z kondenzovaného profilu snímků je získána šířka stopy pomocí metody `getObjectWidth()`. Na základě pozice ze seznamu a šířky stopy jsou vyhledány rohy, získané z Harrisova detektoru, ležící v tomto rozpětí a následně je z nich stanovena souřadnice y , která náleží detekovanému vozidlu. Nakonec dojde k vykreslení detektoru identifikujícího vozidlo, reprezentované kolečkem v dolní části snímku a námi stanovenou pozicí, která je v obraze zobrazena jako křížek. Tyto dva body jsou následně propojeny úsečkou. Je-li identifikace úspěšná, detekovaným vozidlem v obraze prochází úsečka a je na něm zakončena křížkem.

Třída `HMM`

Implementace skrytého Markovova modelu sloužícího pro klasifikaci stopy je provedena v této třídě. Instance této třídy je vytvářena vždy, když dojde k nalezení stopy, která ještě není zpracovávána žádnou jinou instancí. Konstruktoru objektu jsou předávány informace o počáteční pozici a rychlosti bodu a dále ukazatele na matice věrohodností pohybu vozidla a pozadí.

Ze třídy `carTracker` si můžeme ověřit zda-li není stopa již zpracovávána pomocí metody `isProcessed`, které jsou jako parametry předány hodnoty pozice středu stopy a odchylky, kterou představuje celková šířka stopy.

Jelikož ke vkládání nových hodnot dochází ze třídy `carTracker`, metoda `getVelocity()` slouží k získání rychlosti posledního bodu, pro výběr nejlepšího následujícího bodu z možných kandidátů. Pro nastavení navazujícího bodu slouží metoda `setNext`. Pomocí metody `isCar()` si lze ověřit jestli dochází k rozpoznání stopy jako automobilu.

Zda-li došlo k aktualizaci hodnot u všech běžících instancí lze ověřit pomocí metody `isNotSet()`. Funkčnost této metody je zajištěna díky metodě `setValueFalse()`, která všem běžícím instancím nastaví hodnotu `false` do proměnné ověřující aktualizaci hodnot. Za předpokladu, že některé instance nebudou aktualizovány hodnoty, metoda `setLoosing()` se postará o přepnutí instance do režimu predikce pohybu, a pokud nedojde do deseti snímků k aktualizaci hodnot, dochází k zániku instance, který je předcházen testováním všech instancí běžících v režimu predikce pohybu metodou `isLost()`.

Výpočet nového stavu pomocí Viterbiho algoritmu je prováděn privátní metodou `computeNewValues()`.


4.2 Testování a experimenty

Pro testování bylo posbíráno více jak šest hodin videozáznamu z jedoucího automobilu v různou denní dobu a za různých povětrnostních podmínek, na rozmanité škále cest, zahrnujících krom městského provozu také dálnice a silnice okresní. Následně bylo nutné vytvořit testovací množinu dat, která by pokrývala co největší škálu silnic a situací.

Výslednou aplikaci bylo třeba testovat již od počátku implementace, aby bylo možné si ověřit vlastnosti snímků uvedené v kapitole 3, a pro ověření zda dílčí kroky potřebné k úspěšnému dokončení procesu detekce a sledování fungují korektně. Některé dílčí kroky lze pozorovat již v kapitole 3. Jedná se například o obrázky 3.3, 3.4, 3.5, zobrazující jednotlivé kroky extrakce klíčových bodů a následně také profilování intenzit snímků a klíčových bodů, které je patrné na obrázku 3.6. Pro ověření funkčnosti vytváření instancí třídy `HMM` a korektnosti jejich práce, pak sloužil náhled, který můžete vidět na obrázku 4.1

V počátcích testování bylo experimentováno s vyšším rozlišením vstupní videosekvence, a to konkrétně s rozlišením 1280x720 pixelů. Avšak již první kroky extrakce klíčových bodů byly velice pomalé a tedy nevhodné pro zpracování videosnímků v reálném čase, což bylo důvodem pro upuštění od tohoto konceptu a byly pořízeny nové testovací záběry, tentokrát s původním avizovaným rozlišením 640x480 pixelů.

Dalším krokem během vývoje bylo experimentování s různými hodnotami prahů pro funkce `threshold` a dalších parametrů funkce `Sobel`. Bylo nutné vybrat takové hodnoty, které by poskytovaly kvalitní výsledky, a bylo by je možné použít pro další zpracování. Drobnou zajímavostí je, že například špatně zvolená hodnota prahu při získávání profilu



Obrázek 4.1: Ukázka kondenzované profilu $T_f(x, t)$. Kolečka zobrazená v dolní části snímku reprezentují běžící instance třídy HMM.


intenzit horizontálních úseček může způsobit, že snímek bude nepoužitelný pro další zpracování. Přitom se použitelnost, či nepoužitelnost výsledků mnohdy liší hodnotou ± 1 . Z toho důvodu například dochází k úpravám hodnoty prahování při získávání profilu intenzit horizontálních úseček o $+1$, přestože se hodnota tohoto prahu získává adaptivně. Během následujícího kroku, kdy docházelo ke zpracovávání stop běžícími instancemi třídy HMM, byla experimentováním stanovena hodnota, kdy potřebujeme přítomnost vozidla v obraze, aby mohlo dojít ke korektnímu klasifikování, jako 20 snímků, což odpovídá necelé 1 vteřině záznamu.

Finálním krokem testování bylo zpracování vybrané množiny dat a uložení zpracovaných videosekvencí pro analýzu výsledků detekce. Tento krok testování bylo nutné několikrát opakovat, ať už z důvodů vylepšení zobrazení detekovaných vozidel, či z důvodů vylepšení klasifikace automobilů. V původním návrhu ze článku [14], bylo uvedeno klasifikování stopy jako automobilu za předpokladu, že $P(C_t) > P(B_t)$. Při této specifikaci ovšem docházelo k velkému množství tzv. „false alarmů“, tedy těch případů, kdy stopa pozadí byla klasifikována jako automobil, které bylo nutno omezit. Z toho důvodu došlo ke změně návrhu, kdy se stopa klasifikuje jako automobil za předpokladu, že je $P(C_t) > 0.7$. Dalším vylepšením klasifikace bylo implementování predikce pohybu, dojde-li ke ztrátě stopy.

Během testování bylo zjištěno, že rychlost detekce je závislá na složitosti scény. Například scény z dálnice či okresní silnice se dokáží zpracovat s minimálním zpožděním a jsou tedy vhodné pro zpracování v reálném čase. Naopak městské scény, kdy je záběr téměř zaplněn velkým množstvím budov a dalších struktur a přechody mezi světly a stíny jsou markantní,

se zpracovávají pomaleji, a proto při dalším vývoji aplikace by bylo potřeba se zaměřit na tuto oblast, aby se metoda dala použít pro zpracování v reálném čase i pro takto komplexní scény.

Při analýze záběrů, na kterých pozorovatelské vozidlo změnilo směr jízdy, např. odbočením na křižovatce, se změnil celkový optický tok snímku a tedy na detekci se nelze spolehnout, jak je vidět na obrázku 4.2. Po následném ustálení směru jízdy dojde k opětovné stabilizaci detekce.



Obrázek 4.2: (Vlevo) Zobrazuje detekci během odbočení pozorovatelského vozidla, kdy nelze spolehnout na výsledky detekce z důvodu optického toku způsobeného odbočením. (Vpravo) Zobrazuje detekci ve scéně obsahující mostní konstrukci. Jak je vidět ve snímku, zobrazení detekovaných vozidel je ovlivněno klíčovými body mostní konstrukce.

Dalším zajímavým problémem se staly mostní konstrukce tvořící mimoúrovňové křížení s dálničními tahy. Mostní konstrukce tvoří velice silné horizontální úsečky, které ovlivňují profil intenzit horizontálních úseček a tím i samotnou klasifikaci. Během vývoje došlo k omezení tohoto jevu výběrem vhodných hodnot prahů, nedošlo však k celkové eliminaci jevu. Typický příklad lze pozorovat na obrázku 4.2. Dojde-li ke změně osvětlení scény, metoda se dokáže přizpůsobit dostatečně rychle. Dochází-li k detekci automobilu před touto změnou, téměř ve všech případech je sledován dále.

V této sekci byly uvedeny některé zajímavosti získané po čas testování metody. Celkovým vyhodnocením a úspěšností detekce se zabývá následující sekce 4.3.

4.3 Vyhodnocení

Během testování bylo zjištěno, že metoda má potenciál pro zpracování obrazu v reálném čase, neobsahují-li scény příliš komplikované pozadí, jako například při jízdě městem. Jelikož může dojít během vykreslování ke špatnému určení pozice klíčových bodů je jako úspěšná detekce považována i ta situace, kdy vykreslená úsečka protne vozidlo v obraze.


Při dálničních scénách metoda lehce detekuje vozidla jedoucí před námi, dokonce i ve velké vzdálenosti. Identifikace vozidel přijíždějících do záběru z boku je také bezproblémová

za předpokladu, že toto vozidlo nemá příliš velkou rychlost oproti pozorovatelskému vozidlu. V tomto případě může být vozidlo identifikováno špatně a tedy nedetekováno. Detekce je stabilní i pro noční scény, kdy ani nemusí dojít k použití kondenzovaného profilu lokálních extrémů intenzit. Za určitých podmínek, kdy se na snímcích objevují výrazné prvky pozadí, mohou být tyto prvky klasifikovány jako automobil, může tedy dojít k tzv. "false alarmu". Většina těchto prvků jsou ovšem jako vozidla klasifikovány pouze krátkou dobu. Výsledky detekce jsou zobrazeny na obrázku 4.3



Obrázek 4.3: Detekce vozidel při dálničních scénách. (a,b,c,g) Zobrazuje korektní detekci vozidel. (d) Zobrazuje detekci vozidla, do kterého je zahrnut i jeho stín. (e,h,i) Zobrazuje možný výskyt „false alarmů“ společně s detekcí vozidel. (f) Zobrazuje přítomnost „false alarmů“, ke kterým došlo po ztrátě stopy způsobené nedostatečným rozlišením vozidla.

Detekce ve městských scénách je časově náročnější a pro realizaci zpracování v reálném čase by ji bylo nutno řádně optimalizovat, například vytvořením váhové masky pro detekci horizontálních úsečků. Komplikace přináší zejména některé struktury budov v záběru a také časté změny směru jízdy. Ve městě dochází k výskytu „false alarmů“ ve větší míře. Naopak při jízdě po okresních silnicích je klasifikace přesnější a méně časově náročná. Při použití kombinace profilů intenzit horizontálních úsečků a intenzit snímků lze detekovat i malé objekty, jakou jsou motocykly. Výsledky detekce během městského provozu a při jízdě na okresních silnicích je možné vidět na obrázku 4.4.



Obrázek 4.4: Detekce vozidel na okresních silnicích a ve městech. (a,b) Zobrazuje korektní detekci vozidla, během které ale došlo ke špatnému vykreslení. (c) Zobrazuje úspěšnou detekci malých cílů. (d,f) Zobrazuje detekci s „false alarmem“. (e) Zachycuje detekci vozidla v protisměru, způsobenou předními světly automobilu a „false alarmy“.

Během testování bylo ověřeno, že detekce i sledování vozidel dosahuje úspěchu i při náhlé změně světelných podmínek. Dále bylo ověřeno, že při změně směru jízdy pozorovatelského vozidla způsobí zatočení stejný optický tok přes celý snímek, který dělá detekci dočasně nepoužitelnou. Také bylo ověřeno, že je požadován souvislý pohyb pozorovatelského vozidla. Také vysoký kontrast scény vytvoří silné linie, které mohou vést k „false alarmu“. Mostní konstrukce potom mohou způsobit špatné vykreslení detekovaných objektů. Výsledky jsou zobrazeny na obrázku 4.5.

Metoda byla testována na množině dat, která se skládá ze scén zahrnující města, okresní silnice i dálnice, za různých světelných podmínek, a dále pak speciální případy testující limity metody. Na této testovací množině dosahovala metoda většího množství „false alarmů“, většina z nich se ovšem zobrazila jenom krátce. Toto množství „false alarmů“ je způsobeno enormním množstvím stop získaných z profilů, nutných pro zajištění detekce co nejvíce objektů a omezení „miss ratu“. Dosažené výsledky jsou uvedeny v tabulce 4.2.

Klasifikace	Stopy vozidel	Stopy pozadí
Vozidlo	55.04% správně pozitivních	44.96% falešně pozitivních
Pozadí	3.77% falešně negativních	96.23% správně negativních

Tabulka 4.2: Tabulka koeficientů a vstupních hodnot funkcí pro výpočet v Matlabu.

Tyto výsledky ukazují, že metoda s aktuálním nastavením produkuje vysoké množství „false alarmů“, ale kromě pár výjimek, kdy automobil přijíždí do záběru s podstatně větší



Obrázek 4.5: Speciální případy detekce. (a) Zobrazuje prázdnou scény, bez „false alarmů“. (b) Zobrazuje detekci při změně osvětlení scény. (c) Ukazuje špatně vykreslené detekce. (d) Představuje scénu s vysokým kontrastem. (e) Znáznorňuje detekci během zatáčení. (f) Zobrazuje chybu detekce při zastavení.

rychlostí než je rychlost pozorovatelského automobilu, detekuje všechny ostatní vozidla v obraze. Vezmeme-li v potaz 3.77% nedetekovaných vozidel a 44.96% „false alarmů“, dostaneme procentuální neúspěch klasifikace klíčových bodů 24.34%. Potom je tedy celková úspěšnost klasifikace klíčových bodů 75.66%

Kapitola 5

Závěr

V této práci je popsána metoda detekce a sledování automobilů založená na modelu pohybu. Tato metoda je schopná klasifikovat objekty v reálném čase a je tedy za určitých podmínek použitelná ve vestavěných systémech automobilů.

Mým úkolem v této práci bylo vybrat vhodnou metodu detekce automobilu v obraze, nastudovat ji a implementovat. Po domluvě s vedoucím práce byla vybrána vhodná metoda detekce a sledování automobilu, se kterou jsem měl po implementování za úkol experimentovat, řádně ji otestovat a najít možnosti jejího vylepšení.

Podařilo se dosáhnout vysoké úspěšnosti detekce vozidel v obraze, kdy nebylo identifikováno pouze 3.77% automobilů, vyskytujících se v obraze. Tato úspěšnost je bohužel vykoupena větším množstvím „false alarmů“, které se objevují kvůli vysokému počtu získaných stop. Pro omezení tohoto jevu je nutné zkvalitnit proces získávání stop z časoprostorového profilu. Nabízí se různé varianty zkvalitnění procesu, jako je například omezení počtu detekovaných horizontálních úseček, aby došlo k redukci počtu stop v profilech, či porovnávání získaných stop například s profily detekovaných rohů.

Jako další zajímavá oblast zlepšení použitelnosti metody se nabízí zaměření na změnu směru jízdy pozorovatelského vozidla, kdy tato metoda prozatím selhává.

Literatura

- [1] Alonso, D.; Salgado, L.; Nieto, M.: Robust vehicle detection through multidimensional classification for on board video based systems. In *Proc. IEEE ICIP*, ročník 4, září 2007, s. 321–324.
- [2] ŠKODA AUTO a.s.: Cíle - ŠKODA [online]. <http://www.skoda-auto.cz/o-spolecnosti/vyzkum-dopravni-bezpecnosti/cile>, 2013 [cit. 2013-05-14].
- [3] Betke, M.; Nguyen, H.: Highway scene analysis from a moving vehicle under reduces visibility conditions. In *Proc. IEEE Intelligent Vehicles*, říjen 1998, s. 131–136.
- [4] Bruss, A. R.; Horn, B. K. P.: Passive Navigation. In *Computer Vision, Graphics and Image Processing*, ročník 21, Leden 1983, s. 3–20.
- [5] Cheng, H.; Zheng, N.; Sun, C.: Boosted Gabor features applied to vehicle detection. In *Proc. 18th ICPR*, ročník 2, 2006, s. 662–666.
- [6] Flora, G.; Zheng, J. Y.: Adjusting route panoramas with condensed image slices. In *Proc. ACM Conf. Multimedia*, Augsburg, Germany, 2007, s. 815–818.
- [7] Forney, G. D.: The Viterbi Algorithm. In *Proceedings of the IEEE*, ročník 61, Březen 1973, s. 268–287.
- [8] Gao, L.; Li, C.; Fang, T.; aj.: Vehicle detection based on color and edge information. In *Proc. Image Anal. Recog.*, ročník 5112, Lect. Notes Comput. Sci., 2008, s. 142–150.
- [9] Ghosh, N.; Bhanu, B.: Incremental unsupervised three-dimensional vehicle model learning from video. In *Proc. IEEE Transaction On Intelligent Transportation Systems*, ročník 11, Červen 2010, s. 423–440.
- [10] Guo, Y.; Shan, Y.; Sawhney, H.; aj.: PEET: Prototype Embedding and Embedding Transition for matching vehicles over disparate viewpoints. In *Proc. IEEE CVPR*, 2007, s. 17–22.
- [11] Harris, C.; Stephens, M.: A combined corner and edge detector. In *Proc. 4th Alvey Vis. Conf.*, 1988, s. 147–151.

- [12] Hoffmann, C.; Dang, T.; Stiller, C.: Vehicle detection fusing 2D visual features. In *Proc. IEEE Intelligent Vehicles*, červen 2004, s. 280–285.
- [13] Huang, X.; Ariki, Y.; Jack, M.: Hidden Markov models for speech recognition. Edinburgh, UK: Edinburgh University Press, 1990.
- [14] Jazayeri, A.; Cai, H.; Zheng, J. Y.; aj.: Vehicle Detection and Tracking in Car Video Based on Motion Model. In *IEEE Transactions on intelligent transportation systems*, ročník 12, červen 2011, s. 583–595.
- [15] Jiangwei, C.; Lisheng, J.; Lie, G.; aj.: Study on method of detecting preceding vehicle based on monocular camera. In *Proc. IEEE Intelligent Vehicles*, 2004, s. 750–755.
- [16] Jolly, M.-P. D.; Lakshmanan, S.; Jain, A. K.: Vehicle segmentation and classification using deformable templates. In *Proc. IEEE Transactions on pattern analysis and machine intelligence*, ročník 18, březen 1996, s. 293–308.
- [17] Kato, J.; Watanabe, T.; Joga, S.; aj.: An HMM-based segmentation method for traffic monitoring movies. In *Proc. IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 24, září 2002, s. 1291–1296.
- [18] Laganière, R.: *OpenCV 2 Computer Vision Application Programmin Cookbook*. Packt Publishing Ltd., 2011, iISBN 978-1-849513-24-1.
- [19] Lakaemper, R.; Li, S.; Sobel, M.: Correspondences of point sets using particle filters. In *Proc. ICPR*, prosinec 2008, s. 1–5.
- [20] Parodi, P.; Piccioli, G.: A feature-based recognition scheme for traffic scenes. In *Proc. IEEE Intelligent Vehicles*, 1995, s. 229–234.
- [21] Schneiderman, H.; Kanade, T.: A statistical method for 3D object detection applied to faces and cars. In *Proc. IEEE CVPR*, 2000, s. 746–751.
- [22] Sivaraman, S.; Trivedi, M. M.: In *Proc. IEEE Transactions on Intelligent Transportation Systems*, ročník 11, červen 2010, s. 267–276.
- [23] Stirzaker, D.: *Elementary Probability*. Cambridge, U.K.: Cambridge University Press, 2003.
- [24] Takizawa, H.; Yamada, K.; Ito, T.: Vehicels detection using sensor fusion. In *Proc. IEEE Intelligent Vehicles Symposium*, červen 2004, s. 238–243.
- [25] Tan, T. N.; Baker, K. D.: Efficient image gradient based vehicle localization. In *Proc. IEEE Transactions On Image Processing*, ročník 9, srpen 2000, s. 1343–1356.

- [26] Wang, C.-C. R.; Lien, J.-J. J.: Automatic vehicle detection using local features - A statistical approach. In *Proc. IEEE Transactions on intelligent transportation systems*, ročník 9, březen 2008, s. 83–96.
- [27] Zhang, W.; Fang, X. Z.; Yang, X.: Moving vehicles segmentation based on Bayesian framework for Gaussian motion model. In *Pattern Recognition Letters*, ročník 27, 2006, s. 956–967.
- [28] Zheng, J. Y.; Bhupolam, Y.; Tanaka, H. T.: Understanding vehicle motion via spatial integration of intensities. In *Proc. 19th ICPR*, Prosinec 2008, s. 1–5.
- [29] Zhu, Z.; Lu, H.; Hu, J.; aj.: Car detection based on multi-cues integration. In *Proc. 17th ICPR*, ročník 2, 2004, s. 699–702.

Příloha A

Obsah DVD

- Zdrojové soubory aplikace implementující detekční metodu
- Zdrojové kódy pro výpočet matematických funkcí v Matlabu
- Tabulky hodnot vypočítaných funkcí
- Vstupní videosekvence
- Zpracované videosekvence
- Prezentační videoukázka
- Technická zpráva včetně zdrojových textů
- Plakát aplikace